



HAL
open science

Vers une mise à jour de l'occupation du sol du Cameroun par analyse d'imagerie géospatiale et l'exploitation de données cartographiques existantes

Hermann Tagne Taguifang

► To cite this version:

Hermann Tagne Taguifang. Vers une mise à jour de l'occupation du sol du Cameroun par analyse d'imagerie géospatiale et l'exploitation de données cartographiques existantes. Géographie. Université Gustave Eiffel; Université de Douala, 2023. Français. NNT : 2023UEFL2047 . tel-04416532

HAL Id: tel-04416532

<https://theses.hal.science/tel-04416532>

Submitted on 25 Jan 2024

HAL is a multi-disciplinary open access archive for the deposit and dissemination of scientific research documents, whether they are published or not. The documents may come from teaching and research institutions in France or abroad, or from public or private research centers.

L'archive ouverte pluridisciplinaire **HAL**, est destinée au dépôt et à la diffusion de documents scientifiques de niveau recherche, publiés ou non, émanant des établissements d'enseignement et de recherche français ou étrangers, des laboratoires publics ou privés.

Université Gustave Eiffel

Ecole Doctorale Mathématiques et Sciences et Technologies de l'Information
et de la Communication

Laboratoire des Sciences et Technologies de l'Information Géographique

Université de Douala

Ecole Doctorale des Sciences Fondamentales et Appliquées

Laboratoire de Physique Fondamentale

Vers une occupation du sol du Cameroun par analyse d'imagerie géospatiale et l'exploitation de données cartographiques existantes

Par :

Hermann TAGNE TAGUIFANG

Thèse de Doctorat en Physique de l'Environnement :
Sciences et Techniques de l'Information Géographique

Dirigée par : **Clément MALLET** et **David MONKAM**

Présentée et soutenue publiquement le **29 septembre 2023**

Devant le jury composé de :

Serge JANICOT	Directeur de Recherche (IRD/LOCEAN)	Président
Nesrine CHEHATA	Maître de Conférences HDR (Bordeaux INP)	Rapportrice
Clément TCHAWOUA	Professeur (Université de Yaoundé I)	Rapporteur
Anissa MOKRAOUI	Professeure (Université Sorbonne Paris Nord)	Examinatrice
Laurent POLIDORI	Professeur (Universidade Federal do Pará)	Examineur
Joseph KAMGUIA	Directeur de Recherche (MINRESI/INC)	Examineur
Clément MALLET	Directeur de Recherche (LASTIG)	Co-Directeur
David MONKAM	Professeur (Université de Douala)	Co-Directeur
Arnaud LE BRIS	Chargé de Recherche (LASTIG)	Co-Encadreur



Vers une occupation du sol du Cameroun
par analyse d'imagerie géospatiale et
l'exploitation de données cartographiques existantes



H. TAGNE TAGUIFANG



Dédicaces

*A ma mère bien aimée Mafang Hélène,
qui m'a toujours soutenu et encouragé
mais malheureusement, elle nous a quittés
avant de savourer le fruit de ses efforts inlassables.*

*A toi Papa,
A ma femme et mes enfants,
A toutes mes soeurs et frères,
A toutes mes nièces et neveux,
...*

*When you are struggling and you start thinking about giving up, I want you to remember the power of hope.
The belief that something better is always possible if you're willing to work for it and fight for it.
Our hope that if we work hard enough, and believe in ourselves, then we can be whatever we dream,
Regardless of the limitations that others may place on us. The hope that when people see us for who we truly are,
Maybe, just maybe, they too will be inspired to rise to their best possible selves.*

Remerciements

Comme la pluie qui féconde la terre et fait naître la vie, je vois autour de moi la manifestation de la Puissance de DIEU qui me dote de tout ce dont j'ai besoin pour m'accomplir entièrement comme ce terrain qui portera des fruits que d'autres viendront cueillir. Afin de n'oublier personne, je vais commencer par remercier très sincèrement et du fond de mon coeur **tout le Monde**. Il m'est très difficile de contenir dans cette section l'expression de ma reconnaissance envers tous ceux qui m'ont soutenu et accompagné au cours de cette riche et belle aventure.

Avant tout et avec force et vigueur, je vais remercier infiniment mes directeurs et mon co-encadreur de thèse Clément MALLET, David MONKAM et Arnaud LE BRIS respectivement. Durant tout ce parcours, ils n'ont ménagé ni effort ni patience pour m'initier aux sciences atmosphériques et cartographiques. Je tiens à remercier particulièrement Jean-Guy SARKIS et Yolande MUNUAHOK-ATSOMAUTSY du Service de Coopération et d'Action Culturelle (SCAC) de l'ambassade de France au Cameroun pour leur gestion exemplaire de mes séjours en France.

J'exprime ici très spécialement ma gratitude et mon admiration à Clément et Arnaud. Je n'oublierai jamais la subtile façon avec laquelle vous abordiez les difficultés que nous rencontrions au cours des travaux allant dans le sens de les minimiser. Depuis lors, tout semble évident à mes yeux et l'aventure est on ne peut plus passionnante, amusante et merveilleuse. Avec enthousiasme, disponibilité, prévenance, rigueur, et surtout patience, vous m'avez enseigné l'art de la recherche et de la rédaction d'article scientifique. Votre profondeur d'analyses, votre motivation, votre passion et votre sens du travail bien fait ont illuminé mon parcours et me marqueront à jamais. Merci d'avoir toujours été à mon écoute, merci pour vos prompts réactions à toutes mes demandes.

J'adresse ma reconnaissance et mon admiration tout d'abord à Anne PUISSANT et Dino IENCO qui ont accepté d'être membres de mon comité de suivi de thèse d'Université Gustave Eiffel, ensuite au Jury qui me fait l'honneur en me permettant de présenter mes travaux. A Serge JANICOT qui a accepté d'être président, merci pour votre disponibilité légendaire. Merci à Anissa MOKRAOUI et à Laurent POLIDORI d'avoir accepté la délicate tâche d'examineurs. A Clément TCHAWOUA et à Nesrine CHEHATA, je vous suis profondément reconnaissant pour avoir accepté la lourde tâche de rapporteurs. A tous, un grand merci pour l'échange interminable et enrichissant que nous avons eu le privilège d'avoir. Vos remarques, critiques et suggestions m'atteignent profondément en me fournissant des outils de qualité pour mes travaux futurs. Merci pour la marque de confiance que vous m'avez fait savoir.

Cette thèse représente l'aboutissement d'un processus qui a démarré depuis un moment et ayant impliqué pas mal de personnalités formidables à l'instar de Monsieur Martin ELIMBI MBOTTA, Directeur Général de l'Institut National de Cartographie (INC) du Cameroun à qui j'adresse un merci profond et particulier parce qu'il y a cru, il a cru en moi depuis le début en allant chercher pour moi en m'introduisant auprès de Monsieur Alain DUPERET, Directeur Adjoint de l'Ecole Nationale des Sciences Géographiques (ENSG) de France à qui je dis également un grand merci de m'avoir introduit auprès de Clément. Je n'oublie pas Monsieur Joseph KAMGUIA, Directeur de la Production (DP) de l'INC qui a facilité l'obtention des images aériennes nécessaires à la réalisation des travaux de cette thèse et exclusivement disponibles à l'INC. Merci aussi surtout de me faire l'honneur de participer au jury de soutenance de ma thèse en qualité d'examineur.

L'élaboration de ce manuscrit est à surtout mettre à l'actif et au crédit de mon directeur de thèse, Clément MALLET et de mon co-encadreur Arnaud LE BRIS à qui je tiens à redire un grand Merci. En m'accueillant à l'Institut National de l'Information Géographique et Forestière (IGN) de France, vous m'avez non seulement ouvert les portes vers une expertise professionnelle avérée mondialement reconnue mais aussi et surtout m'avez mobilisé tout l'équipement informatique de qualité supérieure et adéquat pour que cette thèse puisse voir le jour en allant à son terme.

Effectuer ma thèse au Laboratoire des Sciences et Technologies de l'Information Géographique (LASTIG) a été une expérience passionnante et enrichissante. J'ai eu l'honneur et la chance de rencontrer des personnes dont la disponibilité et l'ouverture d'esprit m'ont permis de renforcer ma

formation personnellement et académiquement. Merci à LÂMÂN LELEGARD pour m'avoir accueilli dans son bureau et surtout pour ses nombreux conseils. Je n'oublie pas Sidonie CHRISTOPHE, Marc PIERROT-DESEILLIGNY, Bruno VALLET, Valérie GOUET-BRUNET, Loïc LANDRIEU, Mathieu BREDIF, Ewelina RUPNIK et Paul CHAPRON qui par leurs conseils m'ont toujours poussé plus haut. Merci à David CORREIA, pour sa disponibilité et ses nombreux secours sur le plan informatique. J'adresse également un merci chaleureux à Sylvie CACH et Mariam SIDIBE pour leur disponibilité et surtout leur promptitude dans la gestion administrative de mes affaires académiques.

Je ne saurais poursuivre sans remercier les Enseignants de Physique de l'Université de Douala pour avoir facilité la mise en place de ma co-tutelle de thèse. Pour l'accueil et aussi l'organisation des doctorales, me donnant ainsi l'opportunité de pouvoir faire le point sur l'avancement de mes travaux.

D'abord ma promotion « *INC_205 4Ever* » issue des *205 chercheurs* du Ministère de la Recherche Scientifique et de l'Innovation (MINRESI), ensuite à la grande famille du Laboratoire de Traitement d'Images pour la Stéréo-restitution (LATIS) de l'Institut National de Cartographie (INC) du Cameroun, trouvez ici l'expression de mes chaleureux remerciements pour les meilleurs moments passés ensemble durant mes séjours à Yaoundé. Merci à vous tous pour la franche et bonne collaboration. Je pense à NGANDO AKOUMOU, EKEDI MBAPPE, Nasser NGOUH, Edith NKONGNSO et Marlène Tatiana ASSAM qui ont participé à construire une ambiance sympathique et stimulante pour l'éveil scientifique. Je n'oublie pas ESSAPO, CHOUTO, KODNA, SA'A, BEKY, EKOSSO, THAN et NKOUNGOU dont l'enthousiasme communicatif permet à la famille de briller de mille feux.

Je remercie toute ma famille et belle famille pour leurs présences et le soutien infaillible à mon égard. Pardon de vous avoir si souvent délaissés.

L'étude des surfaces continentales est devenue ces dernières années un enjeu majeur à l'échelle mondiale pour la gestion et le suivi des territoires. Dans ce contexte, la télédétection offre des opportunités sans précédent pour détecter la couverture terrestre et produire des cartes d'occupation du sol (OCS) qui jouent un rôle essentiel pour l'étude des changements des surfaces continentales. Le lancement de nouvelles constellations satellitaires - Sentinel-1 et Sentinel-2 - a permis ces dernières années d'acquérir des observations denses de séries temporelles à hautes résolutions (HR). L'arrivée des capteurs à HR spatiales ouvre de nouvelles perspectives ; mais reste limitée pour une discrimination correcte fondée uniquement sur la radiométrie étant donné que les différents types de classes d'OCS ont souvent des couleurs assez similaires (routes, ruelles, pistes, bâtiments) et que de nombreuses zones de nuages et d'ombres sont très souvent présentes sur les images fournies par ces capteurs, questionnant ainsi le choix des méthodologies de cartographie de l'OCS et des données à utiliser en entrée du processus de classification. En plus, ces méthodologies se fondent sur des échantillons d'apprentissage pour améliorer leurs performances de classification. Dans notre cas, la classe associée à une OCS est connue et la qualité de la classification d'OCS dépend directement de la qualité des échantillons d'apprentissage. Or, un grand nombre d'échantillons représentant la diversité des paysages est nécessaire pour la classification sur de grandes étendues. Cependant, la collecte de données de référence sur de grandes étendues est une tâche fastidieuse. Pour obtenir un nombre conséquent d'échantillons sur la zone à classer, les échantillons d'apprentissage sont très souvent extraits d'anciennes bases de données. Toutefois, l'utilisation de ces anciennes données pour classer des images satellitaires plus récentes conduit à des cartes d'OCS imprécises.

L'objectif général de la thèse vise à améliorer les performances de classification de l'OCS dans le but de faciliter sa mise à jour future. Le premier objectif consiste à utiliser différentes approches pour produire des classifications sur de grandes étendues. Plus particulièrement, les travaux portent sur l'analyse des résultats de classifications produites en utilisant trois approches de classifications définies en fonction des données en entrée du système de classification et de l'étendue des zones d'études. De plus, la robustesse de ces approches pour détecter les changements réels d'OCS en présence de changements parasites dus aux conditions météorologiques et climatiques et à d'autres facteurs externes est étudiée. Le second objectif s'intéresse à la contribution d'ortho-images dans l'étude des changements d'OCS. Dans un premier temps, une méthode de génération conjointe d'ortho-images avec des Modèles Numériques de Surface (MNS) est proposée et étudiée. Dans un second temps, un cadre méthodologique est proposé afin de prendre en compte ces ortho-images dans l'analyse des résultats des différentes classifications et fusions de classifications produites. L'objectif est d'arriver à discriminer parfaitement les contours des différents types d'objets à la surface de la terre afin d'augmenter les scores de performance de la classification et faciliter ainsi l'étude et la compréhension de la dynamique en vue de la mise à jour aisée ultérieure de l'OCS du Cameroun.

Mots-clés : Classification supervisée, Fusion, Imagerie géospatiale, Imagerie multi-temporelle satellite, Occupation du sol, Détection de changement, Mise à jour, Cameroun

In recent years, the study of continental surfaces has become a major global issue for the management and monitoring of territories. In this context, remote sensing offers unprecedented opportunities to detect land cover and produce land cover maps that play a key role in studying changes in continental surfaces. The launch of new satellite constellations - Sentinel-1 and Sentinel-2 - has made it possible in recent years to acquire dense observations of high-resolution (HR) time series. The arrival of space HR sensors opens up new perspectives; but remains limited for correct discrimination based solely on radiometry, since the different types of land cover classes often have fairly similar colors and since many areas of clouds and shadows are very often present on the images provided by these sensors, thus questioning the choice of methodologies for mapping the land cover and the data to be used as input to the classification process. In addition, these methodologies are based on learning samples to improve their classification performance. In our case, the class associated with a land cover type is known and the quality of the land cover classification depends directly on the quality of the learning samples. However, a large number of samples representing the landscapes diversity is necessary for classification over large areas. However, reference data collection over large areas is a tedious task. In order to obtain a significant number of samples on the area to be classified, the learning samples are very often extracted from old databases. However, the use of these old data to classify more recent satellite images leads to inaccurate land cover maps and consequently to errors in land cover update.

Taking into account the above mentioned challenges, this Ph.D. work aims at improving the classification performance of the land cover in order to facilitate its future update. The work has been divided into two main parts. The first Ph.D. goal consists in using different classifications processes over large areas by evaluating three classifications approaches with several input datasets and study areas extents. In addition, the stability and the robustness of the classifications approaches to detect real land cover changes in the presence of parasitic changes due to weather and climate and other external factors are discussed. The second goal deals with the contribution of ortho-images in the study of the land cover changes. Firstly, a method for the joint generation of ortho-images with digital surface models (*DSM*) are proposed and analyzed. Secondly, a methodological framework is proposed in order to take into account the ortho-images in the analysis of the classifications and the fusions of classifications results. The objective is to perfectly discriminate the contours of the different land cover types and thus, to increase the classification performance scores and facilitate the study and understanding of the dynamics for the subsequent easy update of the land cover of Cameroon.

Keywords : Supervised classification, Fusion, Geospatial imagery, Multi-temporal satellite imagery, Land cover, Change detection, Update, Cameroon

Table des matières

ix

Dédicaces	i
Remerciements	iii
Résumé	v
Abstract	vii
Table des matières	xi
1 Introduction générale	1
1.1 Contexte	1
1.1.1 Contexte institutionnel : INC / IGN	1
1.1.2 Contexte opérationnel	2
1.1.3 Présentation des OCS et leur nécessité	6
1.1.4 Quelles OCS aujourd’hui pour le Cameroun ?	9
1.2 Problématique et approche proposée	14
1.2.1 Problématique	14
1.2.2 Stratégie générale	16
1.2.3 Organisation du manuscrit	17
2 État de l’art et méthodes	21
2.1 Télédétection géospatiale	22
2.1.1 Introduction	22
2.1.2 Télédétection optique et radar	23
2.2 Des images vers la carte	34
2.2.1 Approches manuelles	34
2.2.2 Approches automatiques	38
2.3 Classification supervisée de séries temporelles	41
2.4 Choix de l’algorithme de classification supervisée	43
2.5 Algorithme de classification : <i>Random Forest</i>	45
2.5.1 Méthodes d’ensemble	45
2.5.2 Arbres de décision binaire	47
2.5.3 De l’arbre à la forêt	50
2.6 Évaluation des performances de l’algorithme de classification	51
2.6.1 Évaluation d’une classification multi-classes	52
2.6.2 Évaluation statistique	54
3 Zones d’étude et données	57
3.1 Zones d’étude	58
3.1.1 Présentation du Cameroun	58
3.1.2 Zone d’étude Nord	65
3.1.3 Zone d’étude Ouest-Centre	68
3.2 Données géospatiales	72
3.2.1 Description des capteurs satellitaires	72
3.2.2 Description des équipements de prise de vues aériennes	74
3.2.3 Pré-traitements des données satellitaires	75
3.2.4 Génération de synthèses mensuelles d’images Sentinel-2	87
3.2.5 Génération conjointe de MNS photogrammétrique et d’ortho-images	90
3.3 Bases de données cartographiques	93

3.3.1	Bases de données cartographiques utilisées	93
3.3.2	Définition et choix d'une nomenclature	103
3.3.3	configurations de nomenclatures étudiées	104
3.3.4	Pré-traitement des données de référence utilisées	104
4	Classification multi-temporelle de l'occupation du sol	109
4.1	Classification supervisée de séries temporelles d'images satellitaires	110
4.1.1	Introduction	110
4.1.2	Données en entrée du système de classification	113
4.2	Chaîne de traitement <i>iota</i> ²	117
4.2.1	Origine de la chaîne <i>iota</i> ²	117
4.2.2	Fonctionnement de la chaîne <i>iota</i> ²	118
4.3	Problématique des données de référence insuffisantes	120
4.3.1	Données de référence insuffisantes en télédétection	120
4.3.2	Données de référence insuffisantes : Incomplétude et décalage	123
4.4	Présentation des expérimentations	124
4.4.1	Images satellitaires et données de référence	125
4.4.2	Stratégie d'échantillonnage pour l'apprentissage supervisé	125
4.4.3	Problématiques et stratégies adoptées	127
4.4.4	Configuration des paramètres du <i>RF</i>	128
4.4.5	Évaluation des résultats	129
4.4.6	Plan d'expérimentations	130
4.5	Auto-entraînement sur l'étendue d'une tuile Sentinel-2	132
4.5.1	Zone d'intérêt <i>T33PUL</i> (<i>ZONE1</i> , Nord)	132
4.5.2	Zone d'intérêt <i>T32NPL</i> (<i>ZONE2</i> , Ouest-Centre)	148
4.6	Stabilité du <i>Random Forest</i> sur l'étendue d'un bloc de tuiles Sentinel-2	165
4.6.1	Évaluation quantitative avec différents modèles sur la zone d'étude <i>ZONE1</i>	165
4.6.2	Artefacts dans les classifications	177
4.6.3	Comparaison pixel à pixel des classifications	182
4.6.4	Comparaison par région des distributions de classes des classifications	184
4.7	Sensibilité aux périodes de synthèse mensuelle de séries d'images Sentinel-2	187
4.7.1	Zone d'intérêt <i>T33PUL</i> (<i>ZONE1</i> , Nord)	187
4.7.2	Zone d'intérêt <i>T32NPL</i> (<i>ZONE2</i> , Ouest-Centre)	207
4.8	Comparaison des classifications avec les autres produits d'OCS	228
4.8.1	Comparaison des classifications et des produits d'OCS sur les zones d'intérêt	228
4.8.2	Enseignements tirés	232
4.9	Conclusion	234
5	Fusion de classifications de l'occupation du sol	239
5.1	Fusion de classifications d'images optiques et radar	240
5.1.1	Introduction	240
5.1.2	Fusion de classifications en télédétection	241
5.2	Présentation des expérimentations	250
5.2.1	Évaluation	250
5.2.2	Problématiques et stratégies adoptées	250
5.2.3	Données satellitaires et de référence	251
5.2.4	Plan d'expérimentations	251
5.3	Apport de séries temporelles d'images Sentinel-1	251
5.3.1	Zone d'intérêt <i>T33PUL</i> (<i>ZONE1</i> , Nord)	252

5.3.2	Zone d'intérêt <i>T32NPL</i> (<i>ZONE2</i> , Ouest-Centre)	267
5.4	Fusion de classifications en alternative à la classification supervisée	284
5.4.1	Zone d'intérêt <i>T33PUL</i> (<i>ZONE1</i> , Nord)	285
5.4.2	Zone d'intérêt <i>T32NPL</i> (<i>ZONE2</i> , Ouest-Centre)	289
5.5	Conclusion	293
6	Conclusion générale et perspectives	297
6.1	Conclusion générale	297
6.1.1	Principaux éléments	297
6.1.2	Contributions et limitations	300
6.2	Perspectives	301
6.2.1	Perspectives méthodologiques	301
6.2.2	Perspectives applicatives	303
	Bibliographie	307
	Annexes	329
A	Données satellitaires et de référence	331
A.1	Dates des images satellitaires utilisées	331
A.2	Niveau de traitements des données satellitaires	334
A.3	Découpage	334
A.4	Nomenclature	334
A.4.1	<i>Land Cover Classification System</i>	334
A.4.2	<i>Base de données de l'INC</i>	342
A.4.3	Légende	342
B	Description des données aériennes	347
B.1	Trajectographie	347
B.2	Stéréopréparation	349
B.3	Aérotriangulation	351
C	Outils logiciels utilisés	359
C.1	Outil logiciel de traitement d'images géospaciales	359
C.1.1	<i>MAJA</i>	359
C.1.2	<i>WASP</i>	359
C.1.3	<i>SNAP</i>	360
C.1.4	<i>MICMAC</i>	360
C.2	Outil logiciel d'analyse des résultats de classification	360
C.2.1	<i>QGIS</i>	360
D	Résultats des comparaisons	363
D.1	Comparaison pixel à pixel	363
D.1.1	Zone d'intérêt <i>T33PUL</i>	363
D.1.2	Zone d'intérêt <i>T32NPL</i>	365
D.1.3	Zone d'étude <i>ZONE1</i>	378
D.2	Comparaison par régions des distributions de classes	380
D.2.1	Zone d'intérêt <i>T33PUL</i>	380
D.2.2	Zone d'intérêt <i>T32NPL</i>	389
D.2.3	Zone d'étude <i>ZONE1</i>	397
E	Liste des publications	406

Introduction générale

[The Computer] was the first machine man built that assisted the power of his brain instead of the strength of his arm.

– Grace Hopper

Sommaire

1.1	Contexte	1
1.1.1	Contexte institutionnel : INC / IGN	1
1.1.2	Contexte opérationnel	2
1.1.3	Présentation des OCS et leur nécessité	6
1.1.4	Quelles OCS aujourd’hui pour le Cameroun?	9
1.2	Problématique et approche proposée	14
1.2.1	Problématique	14
1.2.2	Stratégie générale	16
1.2.3	Organisation du manuscrit	17

1.1 Contexte

1.1.1 Contexte institutionnel : INC / IGN

Cette thèse a été réalisée dans le cadre d’une coopération entre différents organismes camerounais et français (l’Université de Douala (UD) et l’Université Gustave Eiffel (UGE)). Le premier partenaire est l’Institut National de Cartographie (INC) du Cameroun, qui est le principal commanditaire de cette thèse. Celle-ci s’inscrit en effet dans le cadre des travaux de production de sa base de données (BDs) cartographiques d’occupation du sol (OCS) incomplète pour le moment mais qui couvrira à terme l’ensemble du territoire national. Étant le principal fournisseur de BDs topographiques (à l’échelle 1/10000) et cartographiques (à l’échelle 1/25000) et de Modèles Numériques de Terrain (MNT) en cours de production par saisie à partir de données aériennes, sur toute l’étendue du territoire camerounais, l’INC souhaite s’inspirer de BDs géographiques existantes, à l’instar de la BDs Topographique (BD-Topo) de l’Institut National de l’Information Géographique et Forestière (IGN), de la BDs Forêts (végétation) (BD-Forêt) de l’IGN, etc. Dans le cadre de mises à jour futures, l’INC souhaite compléter sa BDs (BD

INC) par l'agrégation d'autres données plus thématiques (e.g. classes agricoles et de végétation). L'*INC* s'intéresse donc à l'exploitation des images satellitaires et/ou ortho-images aériennes afin d'aider à la production, l'enrichissement et la mise à jour de ces *BDs* et répondre ainsi à une large diversité de besoins. La chaîne de production actuelle est en grande partie manuelle et permet d'effectuer des traitements incluant la restitution photogrammétrique à partir de prises de vues numériques d'images aériennes. Elle a été mise en place au cours de l'année 2016. Mais, cette utilisation manuelle de cette chaîne constitue un processus coûteux au niveau de la restitution et rencontre des blocages pour la production d'ortho-images sur des zones de taille un peu conséquente. C'est ainsi que l'*INC* cherche à automatiser ses processus de production pour la cartographie de l'*OCS* du Cameroun. C'est dans ce contexte que se déroule cette thèse. Celle-ci a été menée à l'IGN plus précisément au Laboratoire des Sciences et Technologies de l'Information Géographique (LASTIG), Unité Mixte de Recherche (UMR) de l'IGN et de l'UGE afin d'établir l'étendue jusqu'à laquelle la télédétection peut permettre de cartographier pour une mise à jour ou un enrichissement de la *BD INC* de l'*OCS* du Cameroun.

En effet, les capteurs satellitaires à *HR* spatiale Landsat et Sentinel apportent des images spectralement riches à haute fréquence temporelle et sont par là-même complémentaires à l'imagerie aéroportée et satellitaire multi-spectrale standard. Ces données ont ouvert la voie vers de nouvelles méthodes de production de carte d'*OCS*, par analyse automatique de ces piles de données à l'aide de classifieurs entraînés à partir de *BDs* cartographiques numériques. Ces données de référence sont parfois incomplètes (une partie seulement d'un territoire est couverte), plus à jour ou imprécises. L'IGN, deuxième partenaire de cette coopération, en tant qu'opérateur national ayant pour vocation la constitution de référentiels nationaux sur toute l'étendue du territoire français, en collaboration avec ses partenaires locaux et nationaux. Ces données de référence sont notamment la *BD-Topo* (assez analogue à la *BD INC*) et l'occupation du sol à grande échelle (*OCS-GE*) dont la production doit être en partie automatique à partir de données de télédétection. La constitution initiale de la *BD-Topo* de l'IGN est achevée, mais il s'agit maintenant de la maintenir à jour.

Enfin, cette thèse a été réalisée dans le cadre académique d'une co-tutelle entre l'UD et l'UGE, qui en assurent l'encadrement académique au niveau du laboratoire LASTIG de l'IGN et de l'UGE. Un des axes de recherche du laboratoire porte justement sur le calcul et la mise à jour de données d'*OCS* à grande échelle qui est l'objectif principal et des projets y sont par ailleurs en cours tels que le projet TOSCA PARCELLE dédié à la valorisation et à la capitalisation de la chaîne de traitement automatique opérationnelle *iota*² ou encore le projet ANR MAESTRIA dédié à l'optimisation de la chaîne de traitement en collaboration avec le Centre d'Études Spatiales de la Biosphère (CESBIO).

La suite de ce chapitre présente le contexte opérationnel et la constitution de la *BDs* de l'*INC*. On s'intéressera tout particulièrement aux problèmes que rencontre la *BDs* de l'*INC* et on exprimera des besoins de complétion et de mise à jour de cette dernière.

1.1.2 Contexte opérationnel

Actuellement, il existe un grand nombre d'initiatives de gestion et de suivi du territoire camerounais, notamment en matière d'étalement urbain et de consommation de terres agricoles. Ces initiatives nécessitent l'utilisation d'une *BDs OCS* la plus complète possible couvrant partiellement ou totalement le territoire camerounais. Dans ce contexte, l'*INC*, en tant qu'opérateur national, a pour vocation la constitution d'un référentiel national unique et homogène sur l'ensemble du territoire. La définition par

l'INC de la *BDs* couvrant actuellement partiellement le territoire national a été réalisée par concertation avec un grand nombre d'acteurs locaux, régionaux ou nationaux camerounais. Toutefois, cette *BDs* se focalise plutôt pour le moment sur la description d'objets topographiques anthropiques (e.g. routes, bâtiments etc.), les autres classes d'OCS telles que les zones naturelles ou agricoles sont prévues dans la structure de la *BDs*, mais n'ont pas été saisies pour le moment. Ces classes ne nécessitent pas une description aussi résolue spatialement; mais en revanche, elles restent importantes pour l'exhaustivité de la description des territoires afin d'assurer leur suivi au cours du temps. Elles posent donc malgré tout des contraintes de précision et de cohérence temporelle (**notion de millésime**) afin de répondre à certains principes de compatibilité de nomenclature avec les *BDs* d'OCS existantes et pouvoir permettre de **mise à jour annuelle régulière**.

Deux points sont importants ici, le besoin de cohérence temporelle et de mise à jour régulière. La cohérence temporelle impose de traiter dans les plus brefs délais une grande quantité de données, toutes les données d'OCS devraient être produites. De plus, la mise à jour régulière est un besoin essentiel de certains utilisateurs, afin de permettre une prise de décision sur la *BDs* la plus récente possible pour un suivi **régulier** et **efficace** de l'évolution du territoire camerounais.

Dans le domaine des politiques publiques camerounaises, un très grand nombre de documents d'urbanisme et de lois reposent sur la connaissance de l'étalement urbain et d'indicateurs environnementaux. Cette connaissance repose sur le choix d'une nomenclature dépendant grandement du problème à résoudre. Ainsi, l'INC s'est fait aidé par ses partenaires (locaux et experts) pour commencer la production de sa *BDs* sur les localités des régions du Sud et de l'Extrême-Nord Cameroun. La *BD INC* n'est avant tout qu'un outil de programmation, de planification, de répartition et d'équilibre pour le développement. Elle est constituée d'une *BDs* topographique en cours de constitution et dont le processus de production est non seulement long car effectué selon un processus de saisie manuelle mais aussi et surtout coûteux dû à l'utilisation d'images aériennes ne permettant pas une remise à jour fréquente et à un traitement peu automatisé de ces *PVA*, ni la génération d'ortho-images et de Modèles Numériques de Terrain (*MNT*). Ces insuffisances soulèvent plusieurs questions à savoir :

1. Peut-on automatiser partiellement ou tout au moins utiliser la télédétection pour aider ces processus?

Actuellement seules quelques classes sont saisies (classes topographiques importantes) mais d'autres classes d'OCS sont prévues telles que les classes de végétation (description de la végétation) mais ne sont pas encore saisies car jugées moins prioritaires soulevant la deuxième question de savoir :

2. Peut-on utiliser des capteurs de télédétection pour extraire automatiquement les classes prévues non saisies?

Certains capteurs satellitaires sont moins résolus spatialement mais sont meilleurs spectralement et temporellement que les capteurs de prises de vues aériennes.

3. Peut-on envisager un produit plus grossier que la *BD INC* mais à même d'être généré plus fréquemment à l'échelle du pays et de manière automatique à partir de données de télédétection satellite libres (gratuites)?

Par la suite, la constitution de la *BD INC* qui présente les problèmes précédemment évoqués est détaillée dans cette sous-section. Puis, les problèmes rencontrés dans cette *BDs* sont présentés et

l'enrichissement de cette *BDs* est proposée. Enfin, le besoin des utilisateurs en données rapidement mises à jour et millésimées est analysé.

1.1.2.1 Constitution de la *BD INC*

En concertation avec ses partenaires locaux et nationaux (Ministère de la Recherche Scientifique et de l'Innovation (MINRESI), Ministère des Domaines, du Cadastre et des Affaires Foncières (MINDCAF), Ministère de l'Habitat et du Développement Urbain (MINHDU)), l'INC a constitué une nomenclature nationale qui détaille les éléments à restituer en 3D et en 2D avec leur nature et la méthode de restitution et qui constitue le socle de la *BD INC* en assurant la continuité et la cohérence avec les données existantes et à venir. La nomenclature est hiérarchique et comporte trois niveaux grossiers : les thèmes, les classes et les sous-classes. En particulier, les niveaux correspondant aux thèmes : végétation et OCS sont respectivement hiérarchisés en deux et douze classes OCS. Ces deux thèmes ne sont pas compatibles avec la plupart des *BDs* d'OCS existantes et sont respectivement composés de 16 et 46 classes au niveau le plus fin. Le détail des classes est indiqué dans le Tableau A.1.

Une méthode de création s'appuie sur un ensemble de *BDs* pré-existantes, à l'instar de la *BDs* Topographique de l'IGN (*BD-Topo*), de la *BDs* Forêts (végétation) de l'IGN (*BD-Forêt*), etc. Le processus de création de la *BD INC* est décrit par le schéma de la Figure 1.1. Le thème végétation de la *BD INC* définit le contour des zones de végétation par type (e.g. zone de culture sans arbres (ZC), zone de culture avec arbres (ZCA), zone de culture inondable (ZCI) etc.) et se classe bien dans la chaîne de traitement *iota*² comme démontré dans (TAGNE et al., 2022). Ces premiers résultats doivent permettre l'agrégation d'autres données plus thématiques.

1.1.2.2 Problèmes rencontrés dans la *BD INC*

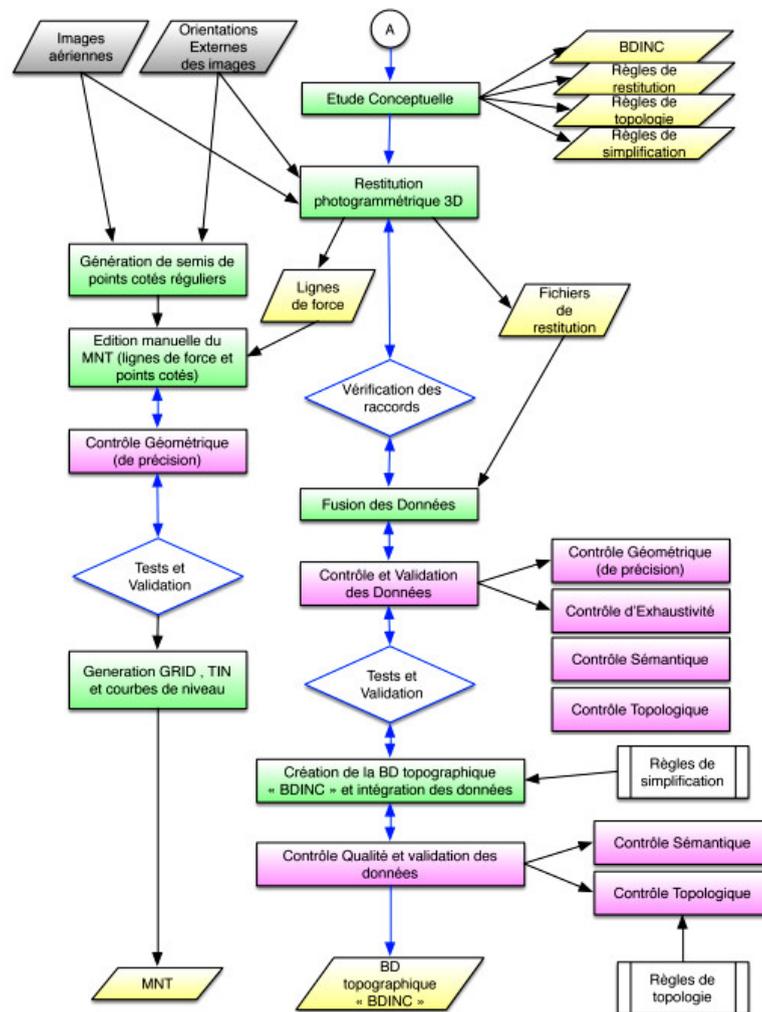
La *BD INC* est traitée manuellement par des opérateurs afin de corriger les erreurs commises au cours des différentes étapes de la restitution. Au cours des contrôles de la restitution, l'étape de correction d'erreurs d'actualité et de complétion est réalisée par photo-interprétation à partir d'une ortho-image aérienne (résolution de 0,3 m) acquise sur la zone. Cette étape est actuellement la plus chronophage pour les opérateurs ($< 2\text{km}^2/h$) et donc la plus onéreuse. Conçue au départ en tant que référentiel de base initial, la *BD INC* rencontre des problèmes dus au manque d'informations, d'insuffisance de la qualité et du contenu des objets déjà saisis.

1.1.2.3 Enrichissement de la *BD INC*

De premiers résultats ont été obtenus en classifiant les classes de végétation à partir de séries temporelles d'images Sentinel-2 (TAGNE et al., 2022). Ils doivent ouvrir la voie à l'extraction d'autres classes d'OCS plus fines et plus thématiques prévues dans la *BD INC* mais qui n'ont pas encore été saisies et qui peuvent à minima jouer le rôle d'habillage d'un fond cartographique avec la possibilité de tester différentes légendes possibles et de tester et comparer différentes stratégies d'apprentissage.

1.1.2.4 Mise à jour de la *BD INC*

Dans les paragraphes précédents, nous avons pu constater un double besoin de complétion et de mise à jour. En effet, les utilisateurs de *BDs* OCS expriment clairement et de manière récurrente un besoin de données qui soient (1) mises à jour le plus régulièrement possible et (2) millésimées, c'est-à-dire, dont l'année de production est la même sur l'ensemble du territoire. Et aucune initiative n'existe visant à fournir de manière régulière, soit une nouvelle version des données d'OCS, soit une carte des changements existants entre la dernière version de la *BD INC* et la version actuelle.



Source : Rapport technique de procédure des différentes étapes de la restitution (Groupement STI/NUMERIX, 2017)

FIG. 1.1 – Processus de création de la *BD INC*.

Toutefois, ce double besoin exige un processus de mise à jour rapide pouvant traiter un très grand volume de données. Il paraît alors nécessaire d'utiliser une méthode en grande partie automatique, afin de faciliter le travail des opérateurs. En effet, le processus actuel repose sur une recherche d'exhaustivité de la *BD INC*, superposée à une ortho-image. L'opérateur effectue ainsi une opération de comparaison visuelle entre ces deux jeux de données pour détecter les éléments à mettre à jour. Ce processus est long, fastidieux et onéreux, pouvant introduire des hétérogénéités sur un territoire.

Ainsi, il est nécessaire de mettre en place des méthodes de mise à jour de la *BD INC* qui seront capables d'automatiser en partie le processus, tout en permettant l'intervention ponctuelle d'opérateurs. Même si l'on ne pourra pas atteindre directement les objets fins (e.g. bâtiments etc.) qui constituent la *BD INC* (pour sa mise à jour ultérieure) à partir de capteurs de télédétection « libres » comme Sentinel, on pourra tout au moins identifier des zones de changements sur lesquelles limiter de futures *PVA*. Ainsi, on pourra assurer le suivi de l'évolution de l'OCS en essayant de proposer une cartographie de l'OCS qui pourrait être produite **automatiquement** et **régulièrement (millésime)** à partir de ces données. Nous verrons dans le Chapitre 2 les types de données pouvant répondre à ce besoin.

Par ailleurs, le processus de production de la *BD INC*, mais également de toutes *BDs* produites par agrégation de différentes données existantes, nécessite tout d'abord une phase de complétion (enrichissement). En effet, les données pré-existantes utilisées peuvent ne pas couvrir l'ensemble du territoire. Ce besoin n'est pas important dans la mesure où il ne concerne que la première itération, mais il mérite d'être signalé, car à l'échelle du pays il devient non négligeable.

1.1.3 Présentation des OCS et leur nécessité

L'OCS (*Land Cover (LC)* en anglais) décrit la couverture bio-physique de la surface des terres émergées. Elle est constituée de la couverture et de l'usage des sols et identifiée par le programme du système mondial d'observation du climat (*SMOC*) (*Global Climate Observing System (GCOS)*) comme l'une des cinq variables climatiques essentielles (*VCE*) (*Essential Climate Variable (ECV)*)¹ hautement prioritaires (*GCOS, 2016*). Ces variables sont sélectionnées pour leur importance dans le cadre de la compréhension et de la prédiction des évolutions du climat, ainsi que pour leur caractère indispensable pour guider les mesures sur l'adaptation et l'atténuation aux changements climatiques. Elles permettent entre autres de soutenir le travail du Groupe d'experts Intergouvernemental sur l'Évolution du Climat (*GIEC*) (*Intergovernmental Panel on Climate Change (IPCC)*) (*IPCC, 2014*).

Les cartes décrivant l'OCS sont de puissants outils scientifiques et décisionnels. Elles sont utilisées dans des travaux de recherche comme entrée des systèmes de modélisation des cycles de l'eau et du carbone ou encore pour les bilans d'énergie (*CLAVERIE et al., 2012*; *HOUGHTON et al., 2012*). Elles servent également pour des applications opérationnelles, notamment pour le suivi des changements à l'échelle mondiale ou continentale, et de supports pour appliquer les consignes et recommandations des politiques publiques qui nécessitent une connaissance précise des territoires (*FEDDEMA et al., 2005*; *IPCC, 2014*; *PIELKE, 2005*).

L'importance de ces cartes a donc conduit à l'émergence de plusieurs initiatives visant à produire des cartes d'OCS et de changements d'OCS. Au niveau **international**, l'ancien projet global d'OCS devenu le programme global d'OCS (*Global Land Programme (GLP)*) mené par *Future Earth*² a par exemple pour objectif de caractériser les changements d'OCS, mais aussi de favoriser l'émergence d'une communauté et de produits accessibles à un plus grand nombre. Un cas spécifique d'OCS concerne le suivi des cultures à grande échelle (*INGLADA et al., 2015b*; *VALERO et al., 2016*), qui est utile dans le cadre de la sécurité alimentaire. Par exemple, le projet de surveillance agricole mondiale (*GEO Global Agricultural Monitoring (GEOGLAM)*)³ vise à fournir de façon opérationnelle des prédictions de récolte aux échelles nationale et mondiale à partir de ces cartes (*WHITCRAFT, BECKER-RESHEF et JUSTICE, 2015*).

En France, une initiative portée par le centre d'expertise scientifique de l'OCS (*CES OSO*) du pôle de données et de services *THEIA* a pour vocation de définir et de développer des algorithmes pour automatiser la production de cartes nationales d'OCS à partir de données satellites. Une seconde initiative nationale, l'OCS à grande échelle (*OCS-GE*) portée par l'IGN, vise à répondre aux problématiques d'aménagement du territoire tout en préservant la biodiversité, les terres agricoles et les continuités

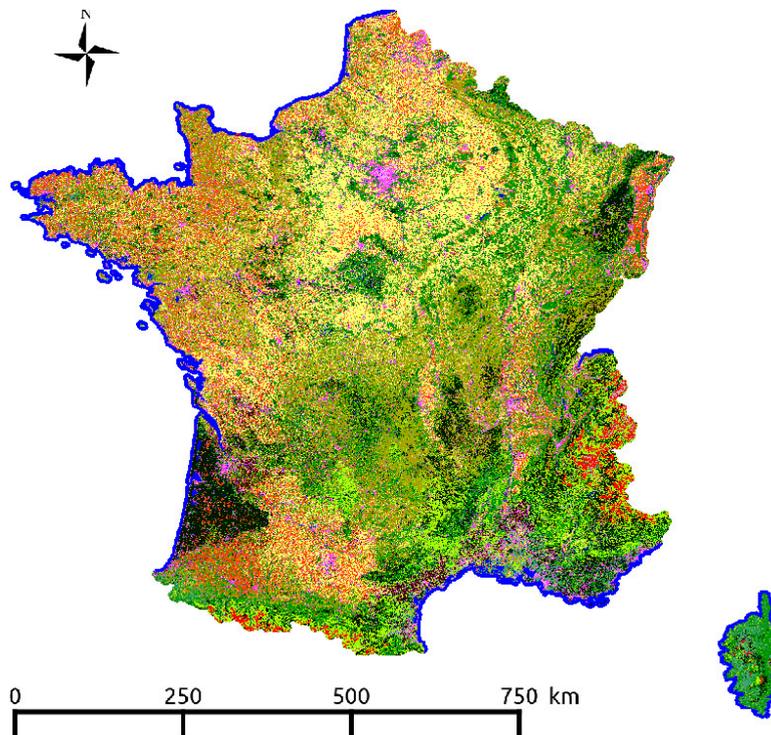
1. Une *VCE* est une variable ou un groupe de variables *physique, chimique* ou *biologique* qui contribue significativement à la caractérisation du climat (*BOJINSKI et al., 2014*).

2. Le projet était nommé *Land Use Land Cover Change (LULCC)* avant 2015, et était conduit par les deux programmes internationaux pour la géosphère et la biosphère (*International Geosphere Biosphere Program (IGBP)*) et pour les changements environnementaux globaux aux échelles humaines (*International Human Dimensions Program on Global Environmental (IHDP)*).

3. <https://www.earthobservations.org/geglam.php>

écologiques - haies, corridors ou encore espaces boisés – pour notamment satisfaire la loi Grenelle II⁴. L'OCS-GE est produite initialement à partir de BDs existantes et complétées par saisie opérateur, mais un nouveau processus plus automatique est en cours de mise en phase. Autour de ces problématiques, de nombreux travaux de recherche se sont développés pour cartographier les infrastructures urbaines ou la Trame Verte et Bleue (MAIRE et al., 2012 ; MASSE, 2013 ; SHEEREN et al., 2012).

À titre d'exemple, la Figure 1.2 montre la carte d'OCS pour la France en 2016 obtenue par le CES OSO. Chaque élément de la carte est associé à une couverture des sols représentée par une couleur. De manière générale, les cartes d'OCS sont caractérisées par :



Source : osr-cesbio.ups-tlse.fr/~oso/posts/2017-04-13-carte-s2-2016/

FIG. 1.2 – Exemple de carte d'OCS. Légende : Annexe A.3.

1. une couverture qui représente la surface du territoire cartographié (partition),
2. la résolution thématique ou sémantique définie par :
 - une nomenclature donnée par la légende qui liste les classes d'OCS cartographiées,
 - la précision sémantique représentant la conformité des OCS attribuées aux objets par rapport à la réalité du terrain,
3. la résolution spatiale définie par :
 - une unité minimale de collecte (UMC) qui correspond à la taille minimale des objets représentés dans une carte sous format vectoriel⁵ ou une résolution spatiale définie par la taille des pixels pour une carte sous format matriciel,

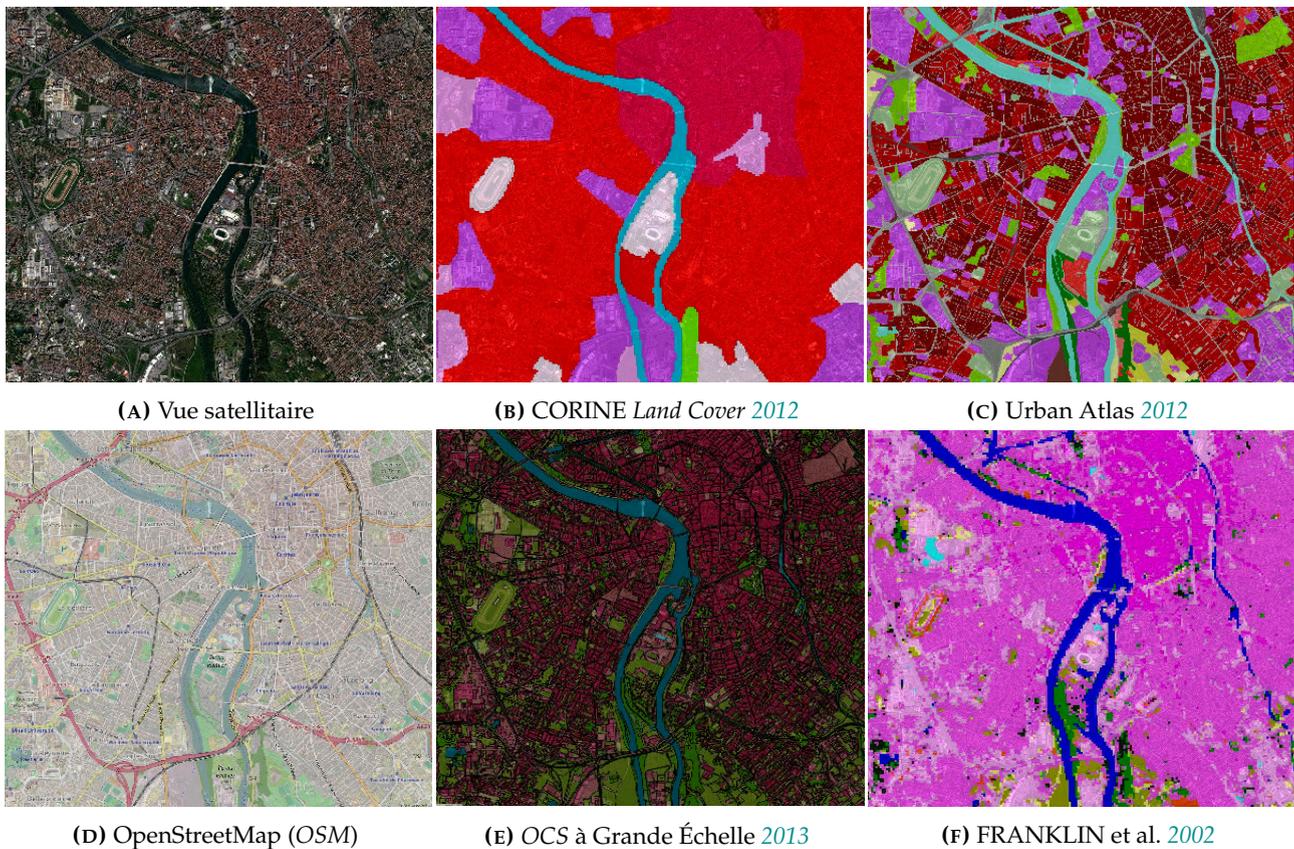
4. Loi N° 2010-788 du 12 juillet 2010 portant engagement national pour l'environnement

5. La notion d'échelle est aussi utilisée pour une carte sous format papier. Elle est définie comme le rapport entre la taille des objets observés sur la carte par rapport à la taille réelle de ces objets. Une échelle de 1/5000 signifie qu'un centimètre sur la carte représente cinquante mètres en réalité.

- la précision géométrique qui définit le degré d'accord sur la position de l'objet dans la carte par rapport à sa position sur le terrain,

4. la temporalité qui inclut :

- l'année de référence qui correspond à l'année représentée par la carte (**millésime**),
- la mise à jour qui correspond à la durée nécessaire pour actualiser l'ensemble de la carte,
- le temps de production qui peut être assimilé à la date de diffusion.



Source : amcarto.alwaysdata.net/demo/test/compa_ocs.html

FIG. 1.3 – Exemple de carte d'OCS, Toulouse, France. Légende : Annexe A.3

La Figure 1.3 montre des cartes d'OCS présentant différentes caractéristiques sur la ville de Toulouse. La première différence visible concerne la nomenclature dont le code couleur est donné par la légende fournie dans l'Annexe A, Figure A.3. La nomenclature de la carte (*Coordination of Information on the Environment (CORINE) Land Cover (CLC)*) (Figure 1.3B) est la moins détaillée, *i.e.* celle avec le moins de classes d'OCS, tandis que celle d'Urban Atlas (Figure 1.3C) est plus détaillée en zone urbaine. Une nomenclature comme celle de CLC (Figure 1.3B) mélange les couvertures, *i.e.* caractéristiques biophysiques, avec les usages des sols (*Land Use* en anglais), *i.e.* la fonction ou le type d'usage que l'homme fait du territoire. Ainsi, les pelouses et les prairies naturelles sont décrites par une même OCS surfaces enherbées. Pourtant, les usages sont différents : les pelouses peuvent servir pour le loisir dans le cadre de terrains sportifs, tandis que les prairies naturelles peuvent accueillir des animaux pour le pâturage et l'élevage.

Par ailleurs, les tailles des objets vus sont très différentes pour les cartes *CLC*, *Urban Atlas* et *OCS-GE* (Figures 1.3B, 1.3C et 1.3E respectivement). Par exemple, les routes ne sont pas visibles sur la carte *CLC* (Figure 1.3B), tandis que toute la structure de la ville est visible avec la carte *Urban Atlas* (Figure 1.3E). Ces différences s'expliquent par l'utilisation d'*UMC* différentes. Ainsi la carte *CLC* (Figure 1.3B) a la plus grande *UMC* à 25 hectares, tandis que la carte *OCS-GE* (Figure 1.3E) a une *UMC* de 0,05 hectare⁶. Au niveau intermédiaire, la carte d'*Urban Atlas* (Figure 1.3C) a une *UMC* de 0,25 hectare⁷.

La carte *CES OSO* (Figure 1.3F) est ici sous format matriciel avec des pixels de 30 mètres × 30 mètres. Une version au format vectoriel en est dérivée pour une *UMC* de 0,1 hectare.

De manière générale, surtout dans le cas de productions nécessitant des photo-interprètes, un compromis est nécessaire entre la taille des objets cartographiés et les coûts de production : les cartes pour lesquelles les objets sont grossiers sont moins coûteuses. Autrement dit, elles nécessitent moins de temps à produire à budget identique. C'est pourquoi, les cartes à petites *UMC* sont produites généralement sur de petites étendues comme les communes ou régions (cas du *MOS IDF*).

En fonction des applications, il n'est pas toujours nécessaire d'avoir un détail très fin des objets qui couvrent de grandes étendues. Par exemple, un plan d'urbanisme dans une commune nécessitera une petite *UMC* pour observer individuellement chaque bâtiment, tandis que l'évaluation quantitative de l'étalement urbain à l'échelle d'un pays nécessitera des cartes plus grandes mais avec des éléments plus grossiers. Concernant le changement climatique, le *GCOS*⁸ recommande la production de trois cartes (*GCOS*, 2016). Deux cartes à moyenne et haute résolutions *HR* spatiales décriront l'*OCS*, tandis que la troisième cartographiera les changements. L'ensemble de ces cartes sera utile pour le suivi des changements, la gestion des ressources, ainsi que pour les études sur la modélisation du changement climatique. Le Tableau 1.1 détaille leurs caractéristiques en termes de mise à jour et de résolutions spatiale et temporelle. Dans toute la suite du manuscrit, on s'intéresse à la couverture des sols.

TAB. 1.1 – Recommandation du *GCOS* pour l'observation des *OCS* dans le cadre des études sur le changement climatique (*GCOS*, 2016).

Produits	<i>OCS MR</i>	<i>OCS HR</i>	Changements <i>OCS</i>
Mise à jour	annuelle	5 ans	1 à 10 ans
résolution spatiale	250 m.	10 à 30 m.	250 m. à 1 km.
Incertitudes sémantiques autorisées (omission et commission par classe)	15 %	5 %	20 %
Incertitudes géométriques autorisées	83 m.	3 à 10 m.	83 à 333 m.

OCS : occupation du sol ; *MR* : moyenne résolution ; *HR* : haute résolution.

1.1.4 Quelles *OCS* aujourd'hui pour le Cameroun ?

La terre et l'eau constituent des éléments basiques mais d'importantes commodités (*KUSHWAHA* et *MUKHOPADHYAY*, 2010). En effet, un intérêt particulier est accordé à la surface de la terre dans le monde entier. Son observation permet ainsi de mieux comprendre le fonctionnement de notre planète. Plusieurs défis sont à relever sur des changements aux échelles mondiale, continentale et nationale au centre desquels la représentation, la description et la compréhension des dynamiques découlant des

6. 0,25 hectare en milieu rural.

7. 1 hectare en milieu rural.

8. *GCOS* : programme qui identifie les *VCE* (page 4).

transformations des surfaces à l'échelle nationale - consommation des espaces naturels, agricoles et forestiers ou expansion urbaine - sont essentielles.

1.1.4.1 Besoins en OCS à l'échelle mondiale ou continentale

Les terres émergées à l'échelle mondiale couvrent environ 183 millions de km^2 représentant 36 % de la superficie totale de la terre dont environ 29 % sont occupés par les zones urbaines tandis que les 7 % restants sont occupés par les espaces naturels, agricoles et forestiers. La population mondiale constituée d'environ 8 milliards de personnes impactent directement l'OCS à travers les actions qu'elle y applique. Les populations rurales influencent particulièrement l'OCS car elles y exercent des activités agricoles nécessaires à leur subsistance en consommant davantage des espaces d'OCS. Les pays en voie de développement tels que le Cameroun ont besoin d'avoir des informations sur l'occupation de leurs sols afin de les aménager, les développer durablement et de surtout éviter une utilisation assez rapide (avec des constructions) et parfois anarchique. Une étude de (KÖHLIN et al., 2012) a rapporté qu'en Afrique, plus de 90 % du bois récolté est utilisé pour l'énergie, et le besoin de bois de cuisine dans les pays à faible revenu demeure important dans un avenir prévisible. De plus, il y a beaucoup de dépendance à l'égard des ressources telles que les matériaux de construction, qui soumettent certaines zones naturelles à des activités d'exploitation forestière. Cependant, le bois n'est pas la seule ressource tirée de la couverture du sol ; nous avons aussi les feuilles d'arbres qui sont utilisées pour les besoins de santé et de nutrition d'environ 80 % de la population de cette partie du monde (FAO, 2010c).

À l'échelle mondiale, la superficie et l'état de la couverture des sols ne cessent de diminuer au cours du temps. Même si les zones naturelles sont d'une grande importance, la connaissance de leurs taux de changement relatifs à l'étalement urbain ou à d'indicateurs environnementaux reste limitée. Il faut également noter que ces taux comportent de fortes incertitudes. Au cours des trois derniers siècles, la superficie de la couverture des sols mondiale était estimée avoir augmenté d'environ 40 % avec 75 % de taux d'augmentation survenu au cours des deux dernières années. Ceci représentait la norme jusqu'en 2005 lorsque l'occupation urbaine a commencé à décroître au profit de la naissance des zones de végétation. Durant cette période de forte augmentation de la superficie de la couverture des sols, (FAO, 2010b) a signalé que la superficie de la couverture des sols d'environ 25 pays avait grandement augmenté et que 29 autres pays avaient perdu plus de 90 % de leurs surfaces agricoles.

Le quatrième rapport d'évaluation du groupe d'experts intergouvernemental sur l'évolution du climat (GIEC) (*Assessment Report of the Intergovernmental Panel on Climate Change (IPCC)*) indique que le secteur forestier, principalement à travers la déforestation, représente environ 17 % du taux global des émissions de gaz à effet de serre. Cela en fait la deuxième source après le secteur de l'énergie (FAO, 2008). Selon le rapport de (FAO, 2010c) sur la couverture des sols à l'échelle mondiale, les taux de déforestation étaient estimés à environ 13 millions d'hectares chaque année entre les années 2000 et 2010. Ceci concernait principalement les pays en développement, avec des taux élevés de déforestation et d'étalement urbain anarchique. Ils ont également mentionné que la déforestation s'effectuait principalement dans les pays tropicaux, alors que les pays développés connaissaient des surfaces d'OCS beaucoup stables. Les pays du Proche-Orient et d'Asie ont également initialement connu une période de déforestation importante qui s'est par la suite stabilisée.

Entre 1990 et 2010, le taux de couverture des sols réservé principalement à l'étalement urbain avait augmenté d'environ 35 % indiquant un engagement des pouvoirs publics des pays en développement à l'aménagement de leurs territoires. Cet étalement va croissant et représente désormais environ 47 %

de l'OCS à l'échelle mondiale. De plus, la couverture des sols continue à tout de même augmenter en Europe et en Amérique du Nord (ACHARD et al., 2002), qui connaissent un étalement urbain d'environ 10 millions d'hectares chaque année. Les causes et les facteurs de la consommation d'espaces naturels, agricoles et forestiers pour des besoins d'aménagement urbain varient d'un endroit à l'autre place, tant au niveau régional qu'international. Ils prennent en compte la mauvaise répartition de l'étalement spatial et les mutations urbaines anarchiques.

1.1.4.2 OCS en Afrique

Dans le continent africain, la végétation couvre environ les deux tiers de la surface de la terre (SKIDMORE et al., 2010). Le continent possède la deuxième plus grande forêt tropicale du monde, après le bassin de l'Amazonie. Les savanes tropicales occupent environ 20 % de la superficie forestière mondiale et dont 65 % se trouvent en Afrique (SHIRIMA et al., 2011). La plupart des pays d'Afrique Centrale ont connu des niveaux variables de menace due au changement climatique, à la dynamique des populations humaines et à la conversion vers d'autres usages. Les éléments moteurs de l'augmentation de la couverture des sols en Afrique Centrale sont, entre autres, le changement généralisé de l'occupation des terres, et la conversion de vastes superficies en zones urbaines, avec la dégradation qui l'accompagne. Dans les régions d'Afrique/Afrique subsaharienne relativement moins développées économiquement, contrairement au rôle que joue l'OCS dans les vies humaines, la connaissance de leur état et la compréhension de leur dynamique en réponse aux changements naturels et anthropiques sont mal comprises. Par exemple, selon (BACCINI et al., 2008) même si les forêts tropicales d'Afrique sont les plus grandes à l'échelle mondiale, elles sont par contre les moins connues en termes d'étendue et de taux de disparition au profit des zones urbaines.

Le continent a également connu une augmentation de la désertification, le surpâturage ayant été la principale cause (FAO, 2008). Le programme des nations unies pour l'environnement (PNUE) (*United Nations Environment Programme (UNEP)*), (UNEP, 2005) a noté que le climat était très variable dans les pays d'Afrique Centrale, mais en même temps, les moyennes saisonnières devenaient plus sèches et plus chaudes résultant d'un changement climatique à long terme. Ceci influence les systèmes socio-économiques des pays d'Afrique Centrale et en particulier sur la demande en eau. A long terme, cela a un effet sur l'irrigation, l'agriculture et la disponibilité en eau potable. Outre les taux élevés de variation d'OCS sous forme de déforestation, le continent a également connu une forte perturbation sous forme de dégradation. Les formes de dégradation les plus courantes sur le continent se font à travers des activités qui aboutissent à une certaine forme de défrichement comme la culture itinérante et l'exploitation forestière. Cependant, il existe toujours une occupation anarchique généralisée des sols en Afrique subsaharienne qui ne permet pas une description précise de l'OCS.

1.1.4.3 OCS au Cameroun

Depuis l'antiquité et le siècle médiéval, l'agriculture et les processus urbains ont toujours sérieusement posé des problèmes, mais avec moins d'acuité. De l'agriculture aux industries extractives, du monde rural aux processus urbains, ces problèmes constituent aujourd'hui une préoccupation majeure à l'échelle mondiale. La maîtrise de l'OCS prend en compte toutes les pratiques anthropiques dans des contextes économiques traditionnels ou modernes tels que l'agriculture, le pâturage, l'exploitation forestière, l'exploitation minière et les processus tels que l'urbanisation avec ses corollaires (WATSON et al., 2000 ; PENMAN et al., 2003). L'OCS implique l'apparence biophysique et les caractéristiques de la

couverture de la surface terrestre telles que la forêt, la savane ou les prairies, les zones humides et les terres nues (WATSON et al., 2000).

Alors que la littérature multidisciplinaire sur l'évolution de l'OCS dans le monde est prolifique, ce n'est pas le cas dans les pays africains comme le Cameroun. A cet égard, certains auteurs (WASSEIGE et al., 2015) ont donné un aperçu général des causes et des facteurs indirects des changements d'OCS et des processus de déforestation dans les pays en développement (GEIST et LAMBIN, 2002; HOSONUMA et al., 2012). De nombreux articles se concentrent directement sur l'OCS (SWART, 2016; DERIBEW et DALACHO, 2019). La déforestation comme principale conséquence du changement d'OCS et de la recherche du développement et de la durabilité, a été sujette à plusieurs études ayant abouti à quelques propositions parmi lesquelles les solutions du programme REDD+ pour l'atténuation et l'adaptation (KISSINGER, HEROLD et SY, 2012; SABOGAL, 2014; SY et HEROLD, 2014; SY et al., 2015b; SY et al., 2015a; SY, 2016).

Au Cameroun, l'OCS a subi de nombreuses transformations depuis l'indépendance en 1960. L'agriculture a été identifiée comme le principal moteur des changements d'OCS, qui ont commencé dès les années 1970 lorsque la politique du plan quinquennal de développement a été lancée (NGWA, 1989; BAMOU et MASTERS, 2007). Ainsi, les activités agricoles combinées à l'exploitation forestière sont les premiers facteurs connus des changements d'OCS. Bien que la déforestation provenant de l'extension des terres agricoles et d'autres types d'OCS est un problème complexe (AGYEI, 1998) en Afrique tropicale. Au Cameroun, le taux de dégradation des forêts a augmenté de 0,01 % entre 1990 et 2000. Ensuite, ce taux a été multiplié par 9 entre 2000 et 2005 (FAO, 2011). Au cours des trois dernières décennies, il a été aggravé par l'urbanisation et les activités extractives.

Un pays apparaissant comme un carrefour de tout commerce, un centre d'enrichissement, de tourisme, d'industrialisation, sa construction passe par le processus d'urbanisation de pouvoir politique. Cependant, la pauvreté peut être considérée comme l'élément qui ternit ce pouvoir et notamment dans le tiers monde (TCHINDJANG, 2010; TCHINDJANG, 2019). L'OCS est un élément important pour l'urbanisation qui menace la biodiversité et augmente la pression sur le régime foncier. En raison de la mondialisation et de la modernisation, l'urbanisation devient le principal facteur sous-jacent des changements d'OCS dans de nombreuses villes africaines (WALL et al., 2018a) même s'il n'y a que peu d'études disponibles dans certains pays comme l'Éthiopie, le Ghana et la Zambie (ROBIN, RUSSELL et al., 2000; UNRUH, CLIGGET et HAY, 2005; AKUBIA, 2016). Les transformations d'OCS liées à l'urbanisation s'accroissent et deviennent des défis majeurs en Afrique avec 40 % de la population (400 millions d'africains) vivant aujourd'hui en milieu urbain, et selon UNHABITAT (WALL et al., 2018b), ils seront 60 % en 2050. En 2025, la capitale du Cameroun, Yaoundé pourrait atteindre 4 à 5 millions d'habitants. Ainsi, l'étalement urbain avec la croissance démographique et la migration sont les principaux facteurs à l'origine des changements globaux et de la déforestation dans les zones d'étude. Depuis 1990, il existe au Cameroun, une expansion massive des terres cultivées, des implantations et des développements d'infrastructures se font au détriment des forêts. Une telle situation d'étalement urbain impacte grandement les changements d'OCS. Dans la plupart des villes camerounaises, la pression démographique a transformé les terres forestières initiales et terres boisées en terres agraires se combinant pour alimenter les activités liées au bois, comme observé dans les villes de taille moyenne du Cameroun comme Bamenda (KAMGA et al., 2013), Bafoussam (TCHINDJANG, 2012), Garoua (ATANGANA et al., 2010) et Maroua (TCHINDJANG et al., 2012).

C'est un pays dont la majorité de la population dépend encore des ressources naturelles pour subvenir à ses besoins. Par exemple, le tourisme basé en grande partie sur ses écosystèmes, sa faune et ses paysages à la fois terrestres et marins, contribuent à plus de 12 % du Produit Intérieur Brut (*PIB*) national. Ces gains accumulés des ressources de la biodiversité sont susceptibles de cesser avec les menaces posées par la perte de la biodiversité. L'expansion de l'agriculture, l'urbanisation, les changements climatiques et la désertification sont les principales causes de perte de biodiversité. Des solutions sont nécessaires sur le long terme sous forme de développement et de mise en oeuvre de politiques pour faire face à la perte de la biodiversité en maîtrisant la couverture des sols. Le renforcement des capacités institutionnelles et le déploiement de ressources adéquates pour gérer cette *OCS* est également important.

Le Cameroun est l'un des pays pilotes du programme de dégradation dans les pays en développement (*REDD+*) pour la réduction des émissions dues à la déforestation consécutive aux changements d'*OCS*. *REDD+* est un mécanisme politique issu de la Convention Cadre des Nations Unies sur les Changements Climatiques, comme une initiative collaborative pour aider les pays en développement à renforcer leurs capacités de réduction des émissions et participer à un futur mécanisme *REDD+* (ONU-*REDD*, 2011). Les émissions sont réduites grâce à l'utilisation et la gestion rationnelle des *OCS*, qui à leur tour fournissent des co-bénéfices de la conservation de la biodiversité et du soutien aux moyens de subsistance (BURGESS et al., 2010; DANIELSEN et al., 2011). Pouvoir répondre aux exigences du programme *REDD+*, davantage de recherches sont nécessaires pour comprendre l'évolution, ainsi que des techniques avancées pour cartographier et surveiller l'*OCS* au Cameroun.

L'opportunité offerte par la configuration spectrale (sensiblement 4 canaux) du capteur optique satellite Sentinel fournissant des séries temporelles à haute résolution (*HR*) spatiale et le bénéfice du capteur aérien permettant la génération d'ortho-images à très haute résolution (*THR*) spatiale (qualité géométrique, résolution spatiale) conjointement avec des Modèles Numériques de Surface (*MNS*), permet désormais d'obtenir une sémantisation correcte fondée sur la radiométrie.

Aujourd'hui, il existe des stratégies, à l'échelle de pays (Chine, États-Unis, France, République Tchèque, Maroc, etc.) et de continents, pour mettre à jour des référentiels cartographiques à très grande échelle. On sait désormais créer automatique des *OCS* avec de la classification supervisée à large échelle (BROWN et al., 2022) sans aucune limitation en terme d'emprise spatiale, de classes discriminées (principalement les cultures) et de résolution spatiale. La recherche relative à la génération automatique de l'*OCS* en vue d'initier ou de mettre à jour des données cartographiques a connu des changements majeurs ces dernières années et vise à développer des méthodes qui s'adaptent assez bien aux changements de paysage existants, comme c'est le cas au Cameroun.

1.1.4.4 Comparaison des bases de données d'*OSM* et de l'*INC*

Il faut bien souligner les différences de finalité entre les données d'OpenStreetMap (*OSM*) et celles de l'*INC* : les données de l'*INC* sont des données de référence à l'échelle du Cameroun, l'*INC* ayant une mission de service public qui l'oblige à représenter l'ensemble du territoire de manière uniforme et avec une excellente qualité. En revanche les données d'*OSM* sont issues de contributeurs volontaires qui ne bénéficient pas des mêmes moyens, mais qui oeuvrent pour créer une information géographique, accessible et utilisable pour tous. Ces deux *BDs* n'ont donc pas la même finalité et ne sont pas produites de manière semblable.

Par ailleurs les deux *BDs* sont différentes aussi bien dans la structuration des données que dans les spécifications (géométrie, attributs). Dans la *BD INC*, les relations topologiques sont appuyées, comme pour la plupart des données géographiques, sur une structure de graphe. Dans la *BDs d'OSM* (*BD OSM*), les données sont organisées en primitives. Il en existe trois types : 1) les noeuds avec un identifiant, des tags et des coordonnées géographiques, 2) les chemins formés d'une succession de noeuds avec un identifiant et des tags, et 3) les relations rassemblant une ou plusieurs primitives, chacune ayant en plus un attribut de type *rôle*. Les relations permettent de lier ou de modéliser des objets sans avoir à dupliquer des géométries *e.g.* un parcours de bus.

Afin de normaliser l'acquisition des données, l'INC a mis en place un cahier des charges sur lequel sont indiquées toutes les spécifications pour le levé. En ce qui concerne *OSM*, il existe également un document qui a pour but d'homogénéiser la représentation du tracé, mais il n'existe pas de spécifications concernant le levé. Par exemple, pour les tronçons de routes, l'INC s'appuie sur l'axe de la voie en tenant compte du bas-côté, tandis que les spécifications d'*OSM* n'indiquent pas sur quel axe il faut se baser. Dans nos travaux de recherche, nous avons été contraints de partir de l'hypothèse qu'*OSM* et l'INC avaient la même notion d'axe de voie afin d'effectuer les analyses comparatives des résultats obtenus dans les différentes configurations des expérimentations menées. Cette absence de spécification a donc été prise en compte durant les études.

1.2 Problématique et approche proposée

1.2.1 Problématique

La problématique traitée dans ce manuscrit porte sur la mise en place d'une cartographie automatique de l'OCS du Cameroun en vue de son suivi et sa mise à jour ultérieure, besoin exprimé non seulement par les utilisateurs de ce type de données mais aussi par les décideurs par exemple pour intervenir de manière efficace dans l'aménagement du territoire par exemple. En effet, nous avons pu constater plus haut que le besoin de mise à jour et de cohérence temporelle des données (notion de millésime) nécessite le développement de méthodes les plus automatiques possible afin de traiter rapidement des zones étendues. Par ailleurs, l'émergence d'un grand nombre de capteurs satellitaires avec des résolutions de plus en plus fines et des exemples existants de l'utilisation grandissante de ces données permet d'exploiter raisonnablement de telles images afin d'envisager de proposer une chaîne de production automatique d'une *BDs OCS* du Cameroun.

Nous considérons ici que les *BDs* cartographiques d'OCS pouvant aider la mise à jour de la *BD INC* sont insuffisantes. Il s'agit donc d'abord de s'intéresser à la constitution de ce que serait une couche OCS sur le Cameroun. On souhaite qu'elle puisse être calculée/produite automatiquement à partir de données de télédétection; ce qui autoriserait sa production rapide et sa mise à jour. Dans le cas présent, les données considérées sont les images (séries temporelles) Sentinel-1 et Sentinel-2 du programme Copernicus (disponibles librement). Le processus de production reposerait sur une classification supervisée. En particulier, on souhaite pouvoir entraîner notre classifieur à partir de jeux de données constitués d'un mélange de *BDs* incomplètes ou nécessitant d'être mises à jour et de *BDs* bien moins résolues spatialement et que l'on souhaiterait raffiner géométriquement.

Un tel produit présenterait l'avantage d'être généré de manière régulière (*e.g.* annuellement) et de donner une image de l'état de la couverture du sol sur l'ensemble du territoire camerounais.

Bien que de moindre résolution spatiale d'environ 250 m par rapport à la BD INC, il pourrait toutefois aider à la production et à la mise à jour de cette dernière par la cartographie automatique de certains thèmes prévus dans la BD INC mais non encore saisis (comme par exemple certaines classes de végétation), ou certains thèmes jouant surtout un rôle d'habillage de fond cartographique :

1. pour le possible enrichissement de certaines de ces classes ?
2. pour la détermination de possibles zones de changement nécessitant une mise à jour (et une nouvelle prise de vue aérienne ou satellite THR localisée) ?

Tout cela pose donc la question de la définition d'un tel produit, compatible avec un processus de production automatique. Il est donc question de définir sa nomenclature de manière à ce qu'elle soit compatible avec une production à partir de données de télédétection mais aussi avec un apprentissage à partir de BDs existantes mais insuffisantes.

Ensuite, se pose la question de la chaîne de traitement automatique à mettre en oeuvre pour la produire. On souhaite ici partir de données satellites disponibles librement, plus précisément de séries temporelles annuelles Sentinel-1 et Sentinel-2. En effet, ces données permettent de visualiser chaque point du territoire à différentes saisons, et donc de « voir » les différents types de couverture du sol sous différents aspects permettant de les caractériser. Par ailleurs, ces séries temporelles denses laissent espérer pouvoir contourner les problèmes d'ennuagement inhérents à certaines parties du Cameroun. Enfin se poseront des questions liées à leur utilisation pratique pouvant s'avérer complexe/problématique du fait de leur volume et des importants temps de calcul que leur traitement occasionne. Trois points de questionnement peuvent donc être soulignés :

1. peut-on définir une chaîne de traitement de séries temporelles d'images satellitaires à haute résolution spatiale pour proposer une OCS annuelle pour le Cameroun ?
2. quelles sources d'information sont les plus pertinentes pour définir le meilleur compromis entre qualité et temps de calcul ?
 - quelles données d'OCS sont pertinentes dans un objectif d'apprentissage d'un classifieur supervisé ?
 - quelles dates et volumes d'images sont les plus adaptées ?
3. quels sont les apports d'une couverture d'images aériennes photogrammétriques ?

Les méthodes de classification actuelles souffrent d'un manque de robustesse, en particulier lorsque les données de référence issues généralement de BDs différentes sont complexes (fortes hétérogénéités). La méthodologie de cartographie proposée devra s'appliquer à réduire au maximum les erreurs liées à l'utilisation de ces méthodes de classification.

Autrement dit, la méthode devra être automatisée dans la mesure du possible, indépendante autant de la BDs que de l'image servant à la mise à jour, tout en garantissant une robustesse vis-à-vis des classifications utilisées.

Ainsi, l'objectif général de la thèse vise à développer une méthode de cartographie dans le but d'assurer ultérieurement le suivi de l'évolution de l'OCS à partir de nouvelles séries temporelles d'images satellitaires comme celles fournies par les capteurs Sentinel-2.

1.2.2 Stratégie générale

Les principaux verrous à lever durant cette étude portent sur trois points particuliers, dont certains découlent de la problématique décrite précédemment :

- présence de **nuages** et leurs **ombres** sur les images satellitaires ;
- apprentissage sur des **données insuffisantes** et **imparfaites** ;
- définition du régime de supervision et de données en **entrée minimale** pour obtenir des **classifications d'OCS fiables**.

Ainsi, une méthodologie de cartographie à plusieurs sources, configurations et méthodes de fusion, nommée *Multi Source, Multi Configuration, Multi Fusion Method* est proposée. Elle se fonde d'une part sur la constitution des données d'apprentissage à partir de différentes *BDs* et d'autre part, sur la multiplication des classifications et leur fusion. Par ailleurs, la multiplication des configurations de classification et des méthodes de fusion permet de rendre notre méthodologie de cartographie plus robuste que des algorithmes de classification classiques, en prenant en compte l'inhomogénéité des données de référence.

Puis, un processus de traitement constitué d'une chaîne de classification de séries temporelles d'images satellitaires et de méthodes de fusion a été adopté (cf. Figures 4.4 et 5.3). Sachant que l'on ne pourra pas atteindre certains objets tels que les bâtiments à partir des capteurs de télédétection utilisés (ici Sentinel), peut-on permettre d'identifier des zones de changement en proposant une cartographie de l'OCS qui pourrait être produite automatiquement et régulièrement (millésime)? Quelles nomenclatures compatibles avec les données disponibles peut-on proposer? Qu'en est-il de la faisabilité de ces cartes d'OCS et de l'évaluation de la chaîne de classification existante pour ce cas d'étude? Qu'obtient-on en testant et évaluant plusieurs configurations de données de télédétection et de stratégies d'apprentissage? Une question et non des moindres (envisagée mais finalement pas assez aboutie pour être abordée dans le cadre de ce manuscrit) porte sur la classification de l'OCS à partir de la fusion de séries temporelles d'images Sentinel-2 et de prises de vues aériennes.

Ainsi **le premier objectif de cette thèse est d'initier les études sur la cartographie de l'OCS du Cameroun à partir d'une chaîne de traitement de séries temporelles denses d'images satellitaires à haute résolution spatiale**. Les expériences seront menées en se focalisant sur deux zones d'étude et d'adopter trois approches de classification définies en considérant différents jeux de données satellitaires et différentes configurations de *BDs* de référence avec plusieurs nomenclatures et stratégies d'apprentissage en fonction de la taille de la zone d'entraînement suivi de leurs études respectives. **Le second objectif porte sur l'évaluation des différents résultats dans un contexte où l'on ne dispose pas de données de référence indiscutables**, mais au contraire de données très partielles ou grossières. Une pure évaluation quantitative de type taux de bonne classification n'est donc pas suffisante et une évaluation qualitative visuelle par comparaison avec les données Sentinel-2 s'avère difficile car les données ne sont pas forcément assez résolues spatialement pour une photo-interprétation efficace. Aussi, a-t-on souhaité exploiter dans ce but les clichés issus de prises de vue aériennes réalisées pour le compte de l'INC. Un travail a donc été mené afin de les ortho-rectifier (ce qui constituait également un problème pour l'INC) et d'en déduire un Modèle Numérique de Surface (*MNS*). Ces données à *THR* spatiale peuvent donc être co-visualisées avec les résultats de classification et de fusion et aider à leur analyse. Par ailleurs, on avait également envisagé d'exploiter ces résultats dans un processus

automatique en complément des images satellite pour cartographier l'OCS, mais ce travail n'a pas pu aboutir pour manque de temps. Notons aussi que cette thèse avait un objectif fort de formation par la recherche et de transfert de « technologie » en direction de l'INC. Certaines des tâches qui ont été menées (notamment la production d'ortho-images et de MNS) étaient donc spécifiques à ce besoin.

1.2.3 Organisation du manuscrit

Ce manuscrit se décline en six chapitres :

- Le **Chapitre 1** introduit le manuscrit en présentant le contexte des travaux de thèse sur les plans institutionnel et opérationnel. Après avoir présenté brièvement la constitution de la *BD INC* et les problèmes qui y sont rencontrés, la nécessité de mise à jour de la *BD INC* est présentée. Puis, les enjeux autour de la cartographie de l'OCS sont décrites. Enfin, la problématique, la stratégie générale et l'organisation du manuscrit sont détaillées.
- Le **Chapitre 2** présente l'état de l'art et les méthodes utilisées. Il est dédié aux méthodes de classification, notamment celles utilisées pour la classification de séries temporelles d'images Sentinel-2_L2 (S-2_L2) et leurs synthèses mensuelles Sentinel-2_L3 (S-2_L3) à différentes périodes et la fusion de séries temporelles d'images Sentinel-1_L1 (S-1_L1) d'une part avec les images S-2_L2, Sentinel-1_L1/-2_L2 (S-1_L1/-2_L2) et d'autre part avec les synthèses S-2_L3, Sentinel-1_L1/-2_L3 (S-1_L1/-2_L3). Une description technique de l'algorithme de classification utilisé est aussi fournie.
- Le **Chapitre 3** présente les zones d'étude, les données géospatiales et les données de référence utilisées au cours de ces travaux. Une description géographique et physiographique du Cameroun est d'abord fournie suivie de la description des zones d'étude. Puis, les pré-traitements appliqués sur l'ensemble des données ainsi que les générations de synthèses mensuelles S-2_L3, de modèles numériques de surface MNS et d'ortho-images sont aussi décrits. Enfin, le choix d'une nomenclature est discuté et les pré-traitements des données de référence utilisées sont présentés.
- Dans le **Chapitre 4**, la classification de l'OCS est étudiée. Dans l'optique de répondre aux problématiques principales, ce chapitre est dédié aux problèmes concernant le choix des sources d'informations et des nomenclatures qui leurs sont compatibles à fournir en entrée du système de classification. Au cours de ce chapitre, différentes expérimentations sont réalisées notamment pour attester de la stabilité de l'algorithme de classification lors de la cartographie sur de grandes étendues. Plusieurs configurations de classification – nombre de classes, type de données, nombre d'images et plusieurs stratégies d'apprentissage prenant en compte la taille de la zone d'entraînement – sont testées afin d'évaluer statistiquement les performances de classification.
- Le **Chapitre 5** est consacré à la fusion de classifications. Des méthodes de fusion classique par apprentissage sont comparées. L'impact des différentes méthodes de fusion proposées sur les performances de la classification est évalué.
- Le **Chapitre 6** présente la conclusion générale et les perspectives des travaux. Ce chapitre permet de résumer les principaux résultats du manuscrit, et de souligner les conclusions les plus importantes. Les contributions et les limitations sont présentées et les perspectives méthodologiques et applicatives sont aussi discutées.

État de l'art et méthodes

An algorithm must be seen to be believed.

– Donald Knuth

Sommaire

2.1	Téledétection géospatiale	22
2.1.1	Introduction	22
2.1.2	Téledétection optique et radar	23
2.2	Des images vers la carte	34
2.2.1	Approches manuelles	34
2.2.2	Approches automatiques	38
2.3	Classification supervisée de séries temporelles	41
2.4	Choix de l'algorithme de classification supervisée	43
2.5	Algorithme de classification : <i>Random Forest</i>	45
2.5.1	Méthodes d'ensemble	45
2.5.2	Arbres de décision binaire	47
2.5.3	De l'arbre à la forêt	50
2.6	Évaluation des performances de l'algorithme de classification.	51
2.6.1	Évaluation d'une classification multi-classes	52
2.6.2	Évaluation statistique	54

Résumé du chapitre :

La cartographie de l'OCS à partir d'images géospatiales repose sur des méthodes de classification qui ont chacune pour objectif de construire un modèle capable de prédire une étiquette associée à une classe pour chaque pixel de l'image. Dans la littérature, ces algorithmes sont généralement divisés en deux catégories : supervisée et non-supervisée¹.

Aussi appelées *clustering*, les approches non-supervisées ont pour but principal de regrouper les échantillons similaires au sein d'une même classe, *e.g. k-Means, Self-Organizing Map (SOM)*. Les groupes constitués, aussi appelés *clusters*, correspondent à des échantillons similaires qui sont différents d'un *cluster* à l'autre. Par la suite, on associe une classe à chaque *cluster*.

1. Le cas semi-supervisé n'est pas abordé dans ce manuscrit.

Ces approches sont favorisées quand peu de connaissances sur les types d'OCS sont disponibles (EVA et al., 2004; GONG et al., 2013). Cependant, la reconnaissance de groupes d'échantillons similaires est une tâche complexe et fastidieuse qui ne peut être réalisée que par un expert de la zone d'étude. Bien souvent, des post-traitements – fusion ou division de *clusters* – sont nécessaires avant de pouvoir étiqueter les *clusters*, et les faire coïncider avec la nomenclature (LOVELAND et al., 2000). En outre, des pré-traitements sont aussi importants afin d'éviter que les classes de fortes variances pouvant présenter différentes apparences (plusieurs comportements) ne dominent en étant présentes dans plusieurs *clusters* à la fois. De plus, les méthodes non-supervisées sont plus compliquées à mettre en oeuvre lorsque la taille des images – nombre de bandes et nombre de pixels – augmente. Pour toutes ces raisons, les approches supervisées sont généralement privilégiées dans le contexte de la cartographie sur de grandes étendues (KHATAMI, MOUNTRAKIS et STEHMAN, 2016).

Ce chapitre se focalise sur les approches supervisées. Une première partie présente les applications de la cartographie de l'OCS ainsi que les capteurs de télédétection. Une deuxième partie décrit les moyens de production des cartes d'OCS à partir d'images géospatiales. Puis, une troisième partie s'intéresse à l'utilisation des approches supervisées pour la classification de séries temporelles d'images géospatiales dans la littérature. Une quatrième partie discute le choix de l'algorithme de classification dans le contexte de la cartographie de l'OCS. Une cinquième partie détaille alors le principe de fonctionnement de l'algorithme utilisé pendant les travaux. Finalement, une dernière partie décrit le processus d'évaluation de la qualité d'une classification.

2.1 Télédétection géospatiale

2.1.1 Introduction

Cette partie introduit les généralités sur la télédétection comme outil majeur pour la caractérisation des éléments de l'OCS et leur cartographie. Nous pouvons retrouver plus de détail sur les bases théoriques de la télédétection dans les documents des auteurs suivants : (MAITRE, 2001), (MASSONNET et SOUYRIS, 2008). D'autres détails techniques sont à trouver également dans les supports de cours et vidéos pédagogiques de l'École Nationale de Sciences Géographiques (ENSG) de France et de l'Agence Spatiale Européenne (*European Space Agency* (ESA)).

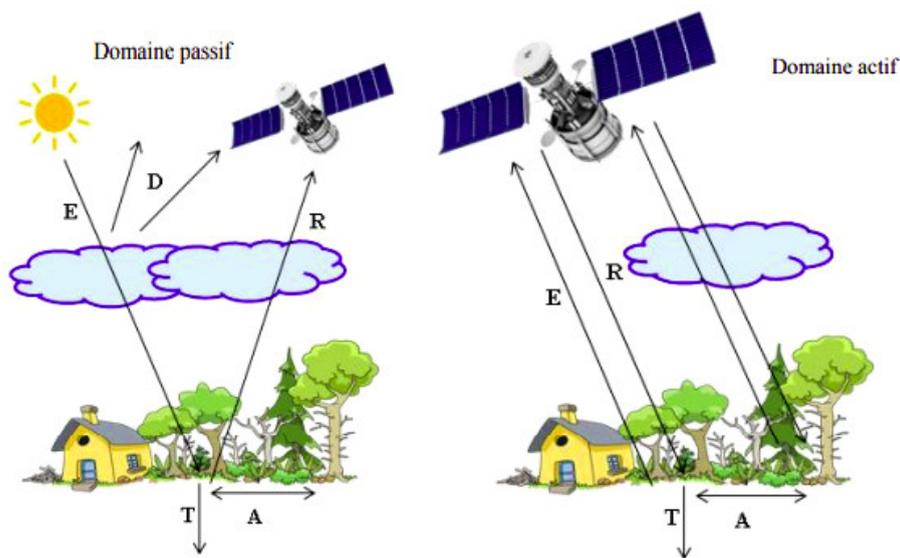
La télédétection joue un rôle majeur car elle permet d'obtenir des informations sur les caractéristiques physiques, biophysiques et biologiques des éléments de la surface terrestre au travers de capteurs qui mesurent à distance des rayonnements électromagnétiques émis ou réfléchis par les éléments de la surface terrestre. Les capteurs de télédétection aéroportés ou satellitaires acquièrent des informations sur de larges surfaces. Ils fournissent ainsi des informations spatialisées nécessaires à l'étude et à la caractérisation des éléments de l'OCS comme la végétation (*e.g.* la végétation tropicale) qui présente un intérêt majeur pour notre étude.

Il existe deux domaines principaux d'acquisition des données par les capteurs de télédétection, le domaine passif et le domaine actif tels que montrés à la Figure 2.1. Le domaine est dit passif lorsque le rayonnement électromagnétique utilisé provient d'une source naturelle comme le soleil. Il est dit actif lorsque le rayonnement électromagnétique provient du capteur lui-même.

Le domaine passif comprend essentiellement des images dites optiques et thermiques. Les capteurs optiques opèrent grâce à des ondes électromagnétiques dans les régions du *visible*, du proche infrarouge

(*PIR*) et du moyen infrarouge (*MIR*) du spectre électromagnétique. Les capteurs thermiques captent les rayonnements réfléchis mais également émis.

Le domaine actif correspond aux images dites *RADAR* (*Radio Detection And Ranging*) et aux données *LIDAR* (*Light Detection and Ranging*). Les *RADAR* utilisent les ondes centimétriques correspondant à la région hyperfréquence du spectre électromagnétique. Comme les capteurs optiques, les *LIDAR* fonctionnent grâce à des ondes électromagnétiques appartenant à la plage spectrale du visible, du *PIR* et du *MIR* avec un domaine actif utilisant la région hyperfréquence du spectre électromagnétique très faiblement sensible aux conditions atmosphériques. C'est ainsi que des images *RADAR* peuvent être acquises de nuit comme de jour et par temps couvert, contrairement à la télédétection des domaines optiques.



Source : www.e-cours.univparis1.fr/modules

FIG. 2.1 – Principe de fonctionnement du domaine actif et passif en télédétection (E : Rayonnement incident/émis, T : Transmis, A : Absorbé, D : Diffusé, R : Réfléchi).

2.1.2 Télédétection optique et radar

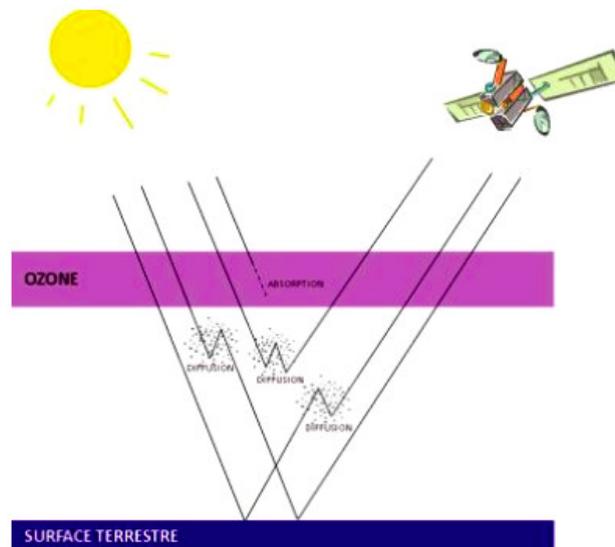
La télédétection offre une diversité importante de données, de méthodologies et d'approches d'analyses des données pour cartographier l'OCS à des niveaux d'échelle variant du niveau local au niveau mondial ou continental en passant par le niveau régional ainsi que de quelques hectares à des milliers de kilomètres carrés (RUNDQUIST, DONALD et LUOHENG, December 1997). Dans le cadre de cette thèse, les données des plateformes *LIDAR* ne sont pas utilisées. Nous avons exploité les données des capteurs optiques et *RADAR*. Selon les capteurs, les paramètres d'acquisition des données, les données et les indices qui dérivent de ces données sont différents. Dans la suite de cette partie nous allons présenter brièvement les caractéristiques associés aux domaines optiques et radar.

2.1.2.1 Télédétection optique

Les imageurs optiques sont des capteurs aérospatiaux qui enregistrent une partie des rayonnements solaires réfléchis à la surface du sol tel que présenté à la Figure 2.2. Chaque capteur optique est caractérisé par les bandes spectrales dans lesquelles il opère. Les bandes spectrales de l'optique sont réparties telles que :

- $0,4 \mu m$ à $0,7 \mu m$ pour le spectre visible.
- $0,7 \mu m$ à $1 \mu m$ pour le spectre *PIR* (signature spectrale de la végétation).
- $1 \mu m$ à $3 \mu m$ pour le spectre *MIR* (signature spectrale de l'humidité des sols).
- $4 \mu m$ à $50 \mu m$ pour le spectre infrarouge thermique.

Les ondes ou les rayonnements émis par le Soleil traversent l'atmosphère, interagissent avec la surface de la terre avant d'être réfléchis par cette surface pour être enregistrés par le capteur. Le signal électromagnétique enregistré doit être traité afin de réduire les effets de l'atmosphère. Cette étape est nécessaire car la trajectoire des ondes ou du rayonnement émis par le soleil comporte une double traversée de l'atmosphère avant et après la réflexion par la surface terrestre, avant d'atteindre le capteur. Dans le cas du domaine thermique, le problème est plus complexe, car la scène observée (surface et atmosphère) est aussi une source émettrice d'énergie.

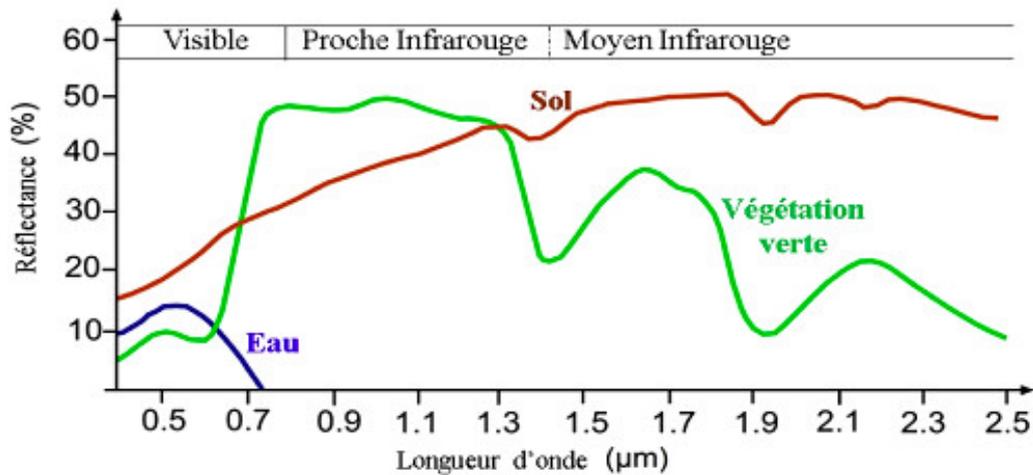


Source : www.e-cours.univparis1.fr/modules

FIG. 2.2 – Double interaction du rayonnement solaire avec l'atmosphère.

Lorsque le rayonnement électromagnétique atteint les objets à la surface, une partie de l'énergie est absorbée (absorption), une autre partie du rayonnement est réfléchi par l'objet. Si l'objet est plus ou moins transparent, il peut éventuellement transmettre une partie du rayonnement, avec un changement de la direction de propagation dû à la réfraction. Le coefficient de réflexion appelé réflectance est la proportion de l'énergie réfléchi par la surface des objets. Elle est fonction de la nature et des caractéristiques intrinsèques des surfaces et de la longueur d'onde. La mesure effectuée au niveau du capteur dépend du flux solaire (éclairage), de l'état de l'atmosphère, de la nature de la surface et de la géométrie d'acquisition (positions du soleil et du capteur). Une modélisation adaptée permet, dans les bons cas, de déduire la réflectance de la mesure (luminance) effectuée au niveau du capteur. Chacune des courbes de la Figure 2.3 décrivant la variation de la réflectance avec la longueur d'onde est appelée signature spectrale. Il s'agit de la principale donnée, issue de la télédétection optique, qui caractérise une surface. Le choix des canaux en imagerie multi-spectrale est guidé par cette signature spectrale. Lorsqu'une image est acquise, certaines bandes sont plus ou moins affectées par certains gaz. Dans le cas particulier où une image est acquise dans une seule et large bande qui couvre tout le domaine visible, on parle d'image panchromatique. Dans la catégorie des

images optiques, on distingue généralement les images satellitaires de celles issues de prises de vues aériennes (même si certains satellites présentent désormais des caractéristiques proches de l'aérien).



Source : www.seos-project.eu/modules

FIG. 2.3 – Signature spectrale de l'eau, du sol nu et de la végétation dans différentes longueurs d'ondes.

2.1.2.1.1 Images satellitaires optiques Cet état de l'art général ne concernera que les données libres d'accès pour les classifications d'OCS locales ou régionales que nous avons menées au cours des expériences. Il sera centré autour de certaines caractéristiques principales de ces images que sont : 1) les orbites d'acquisition, 2) l'effet du relief, et 3) les résolutions d'acquisition (spatiale, les bandes spectrales et la période de revisite).

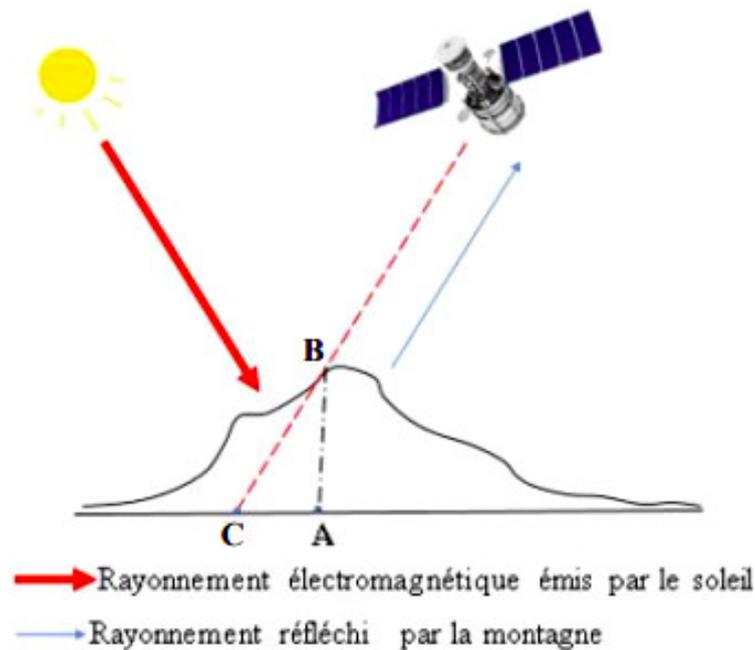
1. Orbites d'acquisition : les satellites optiques d'observation en orbite autour de la terre sont essentiellement de trois types (BONN et ROCHON, 1992) : 1) Orbite géostationnaire : orbite équatoriale et circulaire à une altitude d'environ 36000 km, 2) héliosynchrone : orbite circulaire quasi polaire où le plan de l'orbite du satellite est déterminé de manière à observer régulièrement un point particulier à la même heure locale solaire, et 3) basses non héliosynchrones. Les images de cette étude sont acquises à partir d'orbites héliosynchrones. Cela réduit les variabilités d'éclairage solaire aux variations saisonnières lorsque l'on souhaite comparer plusieurs images. Pour les capteurs usuels, l'acquisition a lieu de jour sur la phase descendante de l'orbite,
2. Effets du relief :

Le relief occasionne des effets radiométriques liés aux variations de direction du flux solaire et des effets géométriques liés aux positions respectives du point imagé et du capteur tel que présenté dans la Figure 2.4. Ceci est aussi valable pour l'aérien.

3. Résolutions d'acquisition :

Trois types de résolution caractérisent un capteur optique :

- Résolution spatiale : surface élémentaire d'échantillonnage observée instantanément par le capteur qui est usuellement simplifiée en taille du pixel sol dans le cas des capteurs optiques.



Source : www.e-cours.univparis1.fr/modules

FIG. 2.4 – Représentation des effets du relief : Le point **B** est localisé comme s'il était en **C** dans le plan de référence : il s'agit d'effet de parallaxe.

- Résolution temporelle (ou répétitivité ou encore période de revisite) : période entre deux acquisitions de la même scène en un point donné ne dépendant pas du capteur ; mais plutôt de l'orbite et du mode de pilotage du satellite. Elle varie de quelques jours à quelques mois et dépend fortement de l'aptitude au dépointage dont bénéficient certains capteurs.
- Résolution (ou configuration) spectrale : bandes de longueurs d'onde auxquelles les capteurs sont sensibles.

Les résolutions spatiales et spectrales sont aussi des concepts valables en aérien.

2.1.2.1.2 Prises de vues aériennes Les prises de vues aériennes sont utilisées depuis plusieurs décennies pour la cartographie de l'OCS (ANDERSON et WOBBER, 1973; COWARDIN et MYERS, 1974). Les prises de vues aériennes anciennes étaient disponibles sur différents supports matériels (film, papier) en mode mono-spectral ou en couleur. Actuellement, les produits sont disponibles nativement en formats numériques, mono et multi-spectraux.

La résolution spatiale des images de prises de vues aériennes est très fine, elle est souvent d'ordre décimétrique (entre 10 et 50 cm) et sont généralement acquises en multi-vues. Ce qui permet d'accéder à une information 3D. Leur très haute résolution *THR* permet de facilement les interpréter/analyser visuellement. Elles peuvent, de ce fait, servir de base pour la délimitation précise des zones d'OCS. Ces données pourront ici être utilisées pour contrôler la qualité des cartographies produites avec d'autres données satellitaires moins résolues spatialement telles que les images multi-temporelles Sentinel-2.

Cependant, les prises de vues aériennes présentent des inconvénients notables à savoir :

- L'acquisition ne peut s'effectuer qu'en l'absence de nuages (le problème se pose aussi avec les satellites à ceci près que les images sont acquises mais pas utilisables).

- Les acquisitions ou les scènes ne couvrent que des emprises limitées et l'acquisition s'avère au final être très onéreuse. Cela peut constituer un frein pour la couverture des grandes régions ou d'un territoire de façon régulière.

Il faut également noter que l'interprétation des images aériennes et satellites par photo-interprétation demande beaucoup de ressources en temps, ce qui peut constituer également une contrainte supplémentaire sur des zones de superficie considérable. Dans cette thèse, les images aériennes ne seront utilisées que pour l'analyse visuelle par superposition des résultats de classifications et de fusions de classifications avec des ortho-images préalablement générées sur certaines zones très localisées.

2.1.2.2 Télédétection radar

Le mot *RADAR* (*Radio Detection And Ranging*) désigne la détection par onde radio et mesure de la distance. Comme nous l'avons évoqué précédemment le système radar est un système actif, c'est-à-dire qu'il illumine une portion du globe terrestre avec une onde électromagnétique et reçoit les échos réfléchis par les objets qui s'y trouvent.

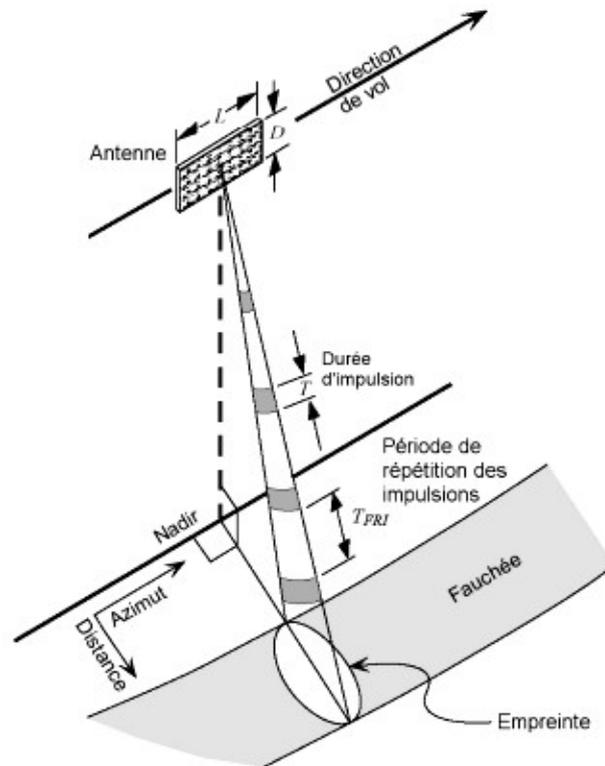
2.1.2.2.1 Principes de fonctionnement Au cours de son déplacement, l'antenne radar ou l'émetteur lance latéralement à intervalles réguliers, des impulsions électromagnétiques très brèves avec une fréquence de répétition fixée en direction des cibles au niveau du sol. Ces cibles réfléchissent les impulsions reçues et l'antenne capte les échos avec un décalage par rapport à l'émission. Le décalage est d'autant plus grand que les cibles sont lointaines.

Après des traitements relativement complexes dits de « *Synthèse d'ouverture* », le système génère une image dans laquelle chaque point correspond à une mesure complexe, une amplitude liée à la puissance reçue selon la cible et une phase liée aux temps de propagation entre l'antenne et les cibles présentes dans le pixel. Ce format de données est dit de type « *Single Look Complex (SLC)* ». En géométrie d'acquisition radar (Figure 2.5), les points du sol sont classés en distance par rapport à l'antenne sur une ligne de l'image *SLC*. Les systèmes radar utilisent une gamme de longueurs d'ondes du domaine des hyperfréquences ou micro-ondes variant de 0,8 cm à 1,3 m. Les longueurs d'onde ou les régions du domaine spectral ont été divisées en bandes. On distingue les bandes : *P*, *L*, *S*, *C*, *X*, *Ku* et *Ka* (voir Tableau 2.1).

TAB. 2.1 – Bandes radar, plages de fréquences et de longueurs d'onde (Centre Canadien de Télédétection (CCT), 1980)

Bande	Fréquence (GHz)	Longueur d'onde (cm)
<i>P</i>	0,23 - 0,39	100 - 30
<i>L</i>	0,39 - 1,55	30 - 15
<i>S</i>	1,55 - 4,20	15 - 7,50
<i>C</i>	4,20 - 5,75	7,50 - 3,75
<i>X</i>	5,75 - 10,90	3,75 - 2,40
<i>Ku</i>	10,90 - 22	2,40 - 1,67
<i>Ka</i>	22 - 36	1,10 - 0,75

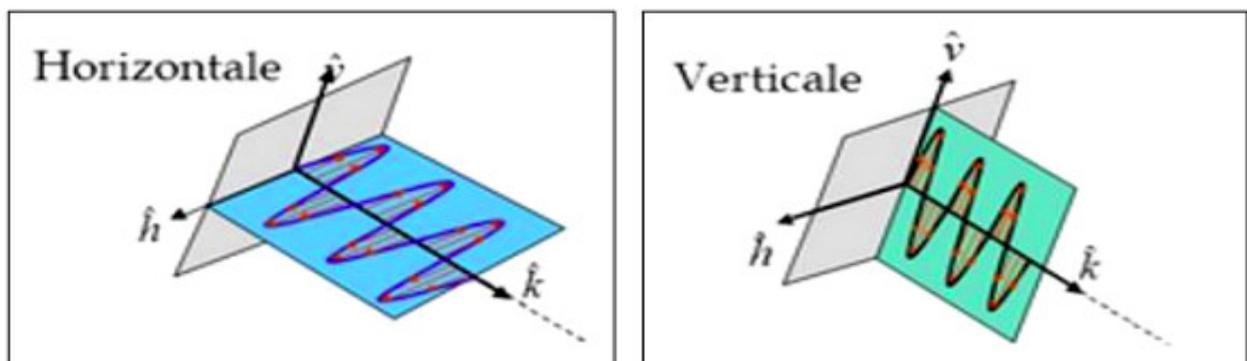
Pour ces longueurs d'onde, les images s'avèrent insensibles aux nuages et voiles nuageux d'où l'intérêt dans des zones tropicales qui sont des zones caractérisées par une persistance de perturbations atmosphériques et des nuages comme le Cameroun par exemple.



Source : (OLMSTED, 1993)

FIG. 2.5 – Géométrie d'acquisition radar.

Par ailleurs, les ondes émises ou reçues peuvent être polarisées dans les systèmes radar. La polarisation joue un rôle important sur la réponse radar et son traitement. Le champ électrique émis par l'émetteur *RADAR* peut être polarisé verticalement (*V*) ou horizontalement (*H*) en relation avec les axes principaux de l'antenne (conduisant à une direction effectivement horizontale *H* perpendiculaire au plan d'incidence pour un sol horizontal et une direction effectivement verticale *V* lorsque l'antenne vise à l'horizontale et que le champ est contenu dans le plan d'incidence, cf. Figure 2.6).

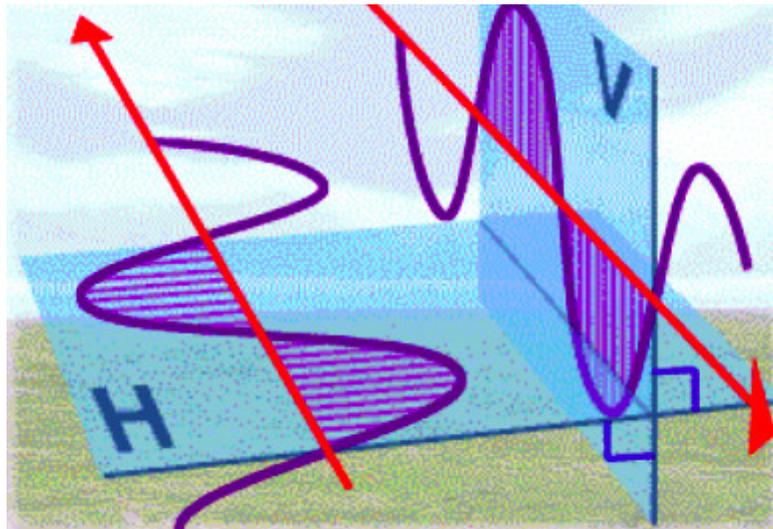


Source : (Centre Canadien de Télédétection (CCT), 1980)

FIG. 2.6 – Polarisations horizontale (*H*) et verticale (*V*) du signal radar.

Le signal rétrodiffusé par les objets de la surface peut ensuite être réceptionné par l'antenne selon l'une des deux polarisations (*V*) ou (*H*). Il en résulte que les polarisations possibles pour une image sont les « co-polarisations » *HH* et *VV* et les « cross-polarisations » *HV* ou *VH*, la première lettre

désignant la polarisation en réception et la seconde celle en émission et pouvant être inversé. Ce problème de nomenclature est négligeable car les deux quantités mesurées dans les polarisations *HV* et *VH* sont égales pour le cas des *RADAR* monostatiques où la même antenne joue le double rôle d'émetteur et de récepteur.



Source : (Centre Canadien de Télédétection (CCT), 1980)

FIG. 2.7 – Polarisation croisée *HV* ou *VH*.

Conformément aux images optiques précédemment décrites, nous allons résumer dans la section suivante les grandes caractéristiques des images radar. Il n'existe pas de différence entre les capteurs aéroportés et satellitaires dans ce cas précis des systèmes radar car les instruments embarqués sont très voisins et la distinction entre les deux types d'images ne présente pas le même caractère historique que dans le cas des prises de vues aériennes et des images satellitaires optiques. De plus, la résolution spatiale est indépendante de la distance Antenne - Sol.

2.1.2.2.2 Images satellitaires radar Cet état de l'art général ne concernera que les données libres d'accès pour les classifications d'OCS locales ou régionales que nous avons menées au cours des expériences. Il sera centré autour de certaines caractéristiques principales de ces images que sont : 1) les orbites d'acquisition, 2) l'effet du relief, et 3) les résolutions d'acquisition (spatiale, les bandes spectrales et la période de revisite). Les images radar sont acquises, selon une visée latérale droite ou gauche à partir d'orbites héliosynchrones en orbite descendante et en orbite montante. L'inclinaison ou l'angle entre les plans orbitaux des orbites montante et descendante est de l'ordre de -8° et $+8^\circ$ par rapport à l'axe de la terre. Les images acquises sur ces deux types d'orbite auront des types d'empreintes (ou d'emprises) différentes et variant fortement avec la latitude. La période de revisite dans les mêmes conditions d'acquisition va diminuer lorsque la fauchée augmente. Cette période de revisite est de quelques jours à quelques mois (ENSG, 2017).

Résolutions des images radar en géométrie sol

Cas d'un sol plat Les images radar sont nativement obtenues en géométrie dite radar où la cellule de résolution est anisotrope, les deux directions longitudinale (ou azimutale) et transversale (ou radiale) n'étant pas équivalentes tel qu'on peut l'observer dans les Figures 2.6 et 2.7 du Centre Canadien de Télédétection (CCT) (CCT, 1980).

La résolution radiale s'exprime en fonction de la durée de l'impulsion radar τ . En effet comme l'onde radar se propage à la vitesse de la lumière c , le temps de trajet aller-retour T d'une impulsion : $T = 2.D/c$ permet de calculer la distance D entre le capteur radar et la surface cible :

$$D = T.c/2. \quad (2.1)$$

La résolution radiale oblique R_r s'exprime en fonction de la durée de l'impulsion radar par la relation suivante :

$$R_r = \tau.c/2. \quad (2.2)$$

La résolution radiale au sol R_s est donnée par la relation suivante :

$$R_s = \tau.c/2.\sin(\theta_{local}), \quad (2.3)$$

avec R_s la résolution radiale au sol dépendant fortement de l'incidence locale θ_{local} dans la direction transverse et indépendante de la distance *antenne-sol*.

L'image radar est construite en utilisant le déplacement de l'antenne dans la direction de vol, permettant ainsi d'éclairer une bande de surface qui correspond à la résolution longitudinale R_a . Les lignes sont acquises progressivement au cours du temps.

Pour un radar à ouverture réelle, la résolution R_a est donnée par la relation suivante :

$$R_a = \lambda.D/d, \quad (2.4)$$

avec λ la longueur d'onde, D la distance *antenne-sol* et d la longueur de l'antenne.

Après le traitement de synthèse d'ouverture (SAR) (MASSONNET et SOUYRIS, 2008), on obtient :

$$R_a = d/2. \quad (2.5)$$

On retrouve une valeur indépendante de la distance *antenne-cible* qui est une propriété déjà rencontrée pour la résolution transversale dans laquelle d est la longueur de l'antenne d'ordre métrique).

Afin d'obtenir des images à pixels carrés, un traitement de correction géométrique est nécessaire. Ce traitement géométrique consiste à transformer la géométrie radar de l'image initiale en une géométrie sol de l'image finale. Dans le cas des images radar, la résolution spatiale ne coïncide pas avec la taille du pixel, que ce soit en géométrie radar ou en géométrie sol avec une valeur différente selon la direction retenue. Ainsi la connaissance de la résolution spatiale liée au capteur donne lieu à un échantillonnage de fréquence adéquate ce qui définit alors la taille du pixel. Cette configuration d'image en géométrie sol avec des pixels carrés est mieux adaptée au traitement ultérieur de l'image radar (ENSG, 2017).

Cas d'un sol en pente : effet du relief Le relief, d'origine naturelle ou anthropique (bâtiments, ouvrages d'art etc.), engendre différentes distorsions géométriques. Ainsi, lorsqu'une onde électromagnétique est réfléchiée par le sommet d'un objet, elle est reçue avant celle renvoyée par la base de ce même objet. Dans le cas simple d'une surface plane de pente p , mesurée algébriquement positivement lorsque la face est orientée vers l'antenne, la résolution dans la direction longitudinale a des valeurs approximativement égales à celle trouvée pour un sol plat. Par contre, la valeur de la résolution transversale (ou radiale) au sol est donnée par la relation suivante :

$$R_{rg} = c/(2.B.\sin(\theta - p)) \quad \text{puisque} \quad (\theta_{local}) = \theta - p, \quad (2.6)$$

avec B la largeur de la bande de modulation sur l'image radar produite.

Différents phénomènes se produisent en fonction de la valeur de la pente :

Phénomène de raccourcissement

Ce phénomène s'observe lorsque la pente face au radar est inférieure à l'incidence. La taille du pixel sol est plus grande et l'image subit une compression.

Phénomène de rabattement

Un objet apparaît comme replié dans la direction du capteur. Il se produit lorsque le sommet de la cible (montagne par exemple) est plus proche du capteur du satellite que la base de cette cible. Ce phénomène s'observe lorsque la pente face au radar est supérieure à l'angle d'incidence.

Pour les faces opposées à l'antenne, leur pente p doit être comptée négativement dans les expressions précédentes et l'image subit une dilatation et le phénomène d'ombre peut apparaître lorsque l'angle d'incidence ($90^\circ - p$) est supérieur (p étant la pente absolue des faces opposées à l'antenne). Ce phénomène apparaît lorsque le relief est suffisamment marqué pour une incidence donnée.

Pour un sol plat, la surface de la cellule de résolution au sol couvre une surface égale à :

$$\Delta S_{sol_plat} = R_a \cdot R_{rg} = (d/2)c / (2.B.\sin(\theta - p)). \quad (2.7)$$

Pour un sol de pente p , nous obtenons :

$$\Delta S_{sol_pente_p} = R_a \cdot R_{rg} = (d/2)c / (2.B.\sin(\theta)). \quad (2.8)$$

La surface du pixel au sol d'une pente p est liée à la surface du pixel au sol plat par :

$$\Delta S_{sol_pente_p} = \Delta S_{sol_plat} (\sin(\theta - p) / \sin(\theta)). \quad (2.9)$$

Ainsi l'existence de pentes occasionne des effets géométriques liés au classement des points sur l'image produite en fonction de la distance à l'antenne du capteur. Il en résulte des effets radiométriques importants car la puissance reçue par l'antenne est proportionnelle à la surface du pixel au sol. Pour un même type de surface en zone plate ou accidentée, nous aurons donc une relation du type :

$$\langle P \rangle_{sol_pente_p} = \langle P \rangle_{sol_plat} (\sin(\theta - p) / \sin(\theta)), \quad (2.10)$$

entre les puissances $\langle P \rangle$ reçues par le capteur en supposant qu'il existe dans cette relation simplifiée, un coefficient de rétrodiffusion radar dont la réponse varie selon la cible observée et ne dépend donc pas ou peu de l'incidence locale.

Au cours de notre travail, différentes zones spécifiques d'étude ont été explorées. Certaines zones au Nord, sont relativement plates et donc très peu affectées par les déformations géométriques telles qu'on peut voir dans (CCT, 1980). C'est le cas de la zone centrée sur la ville de Garoua. Par contre, des déformations géométriques importantes sont observées dans d'autres zones spécifiques à l'Ouest Cameroun notamment sur la ville de Bafoussam, car ces zones sont caractérisées par une forte variation du relief avec des montagnes dont l'altitude peut atteindre 2000 m.

Chatoiement

Une image est composée de points juxtaposés les uns à côté des autres sous forme matricielle. Chaque élément de l'image (pixel) est défini par son amplitude et sa position dans l'image. La réponse individuelle de chaque élément de l'image est caractérisée par une très forte variabilité due à la nature cohérente de l'onde électromagnétique utilisée et réfléchiée par l'ensemble des réflecteurs ou

cibles distribués de manière aléatoire dans le paysage. En termes de champ électrique, cette réponse correspond à la somme des réponses individuelles des cibles élémentaires présentes dans la cellule de résolution. Il en résulte un phénomène d'interférences aléatoires (elles peuvent s'additionner : interférences constructives ou se soustraire : interférences destructives) qui conduit à une réponse en amplitude fortement variable. Une cible homogène formée de nombreux pixels apparaît ainsi avec un aspect « poivre et sel ». Ce phénomène est appelé chatoiement en français et « *speckle* » en anglais.

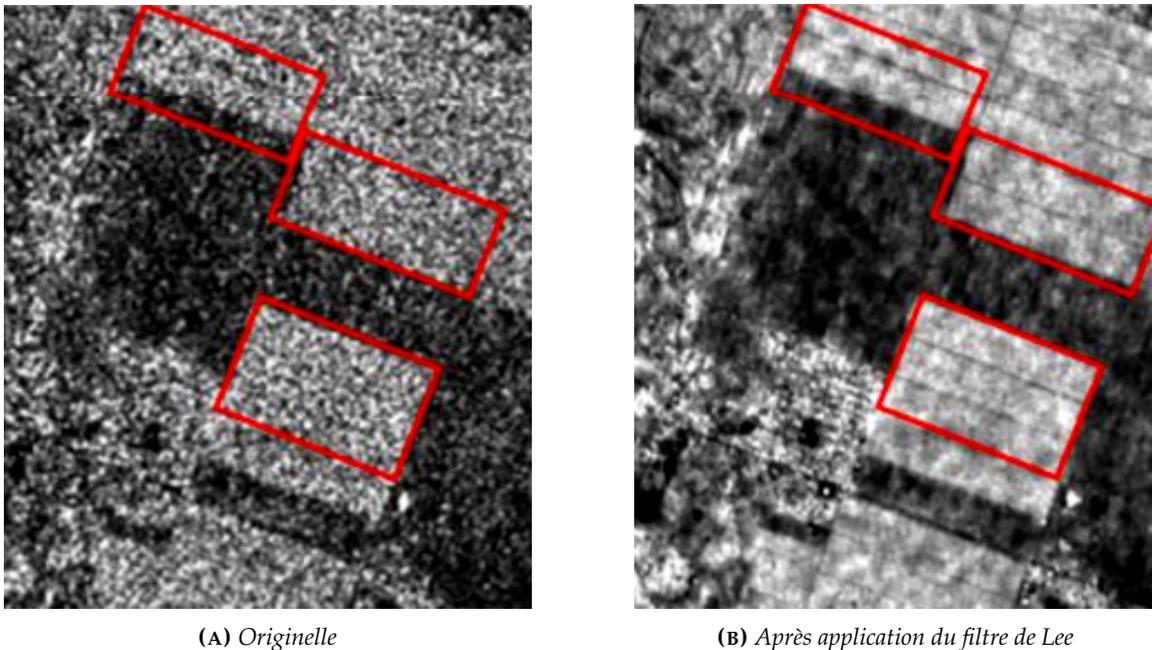


FIG. 2.8 – Image Sentinel-1 extraite sur la zone spécifique d'étude de Garoua.

Les illustrations de la Figure 2.8 extraites des images SAR Sentinel-1 utilisées par la suite dans les travaux de cette thèse présentent le phénomène de « *speckle* » sur des parcelles agricoles (A). L'application d'un filtre passe-bas (numérique) atténue le phénomène et modifie l'aspect de l'image (B). Avec l'apparition de capteurs comme ceux du satellite Sentinel-1 permettant l'acquisition de séries temporelles denses d'images, différents algorithmes fondés sur des approches spatiales ou multi-temporelles, ont été développés afin de réduire le « *speckle* ». Ces algorithmes sont notamment utilisés pour la détection de formes particulières, de contours, ou d'objets (MAITRE, 2001)

Nombre de vues des images radar

Une image native est caractérisée par des cellules de résolution dont l'écho comporte une partie réelle et une partie imaginaire. Cette image correspond à une image à « une vue » ou « *Single Look Complex (SLC)* ». Pour cette image *SLC* sur une zone homogène, la variabilité radiométrique (coefficient de variation) est donnée par les relations suivantes :

- $C_v I = \sigma(I) / \text{esperance}(I) = 1$ avec, $\sigma(I)$ l'écart type de l'intensité,
- $C_v A = \sigma(A) / \text{esperance}(A) = 0,527$ avec, $\sigma(A)$ l'écart type de l'amplitude,

avec I l'intensité, et A l'amplitude telle que : $I = A^2$

Sur les images *SLC*, le coefficient de variation est élevé, ce qui signifie que le chatoiement (effet « poivre et sel ») est maximal. Dans la pratique, on travaille avec des images en géométrie sol dont les pixels carrés ont été obtenus en effectuant une moyenne sur les amplitudes et intensités de l'image *SLC*.

Il s'agit alors d'images dites à « N -Vues », N étant le nombre de pixels moyennés à l'étape précédente, le terme N est appelé le nombre de vues ou « *look* ». Le chatoiement est alors réduit, et N quantifie cette amélioration de l'image. Pour les images radar spatiales livrées en géométrie sol, ce nombre N est en général de l'ordre de 3 ou 4. Il existe deux types de format d'image Sentinel-1 caractérisés par un nombre de vues différent : le format *SLC* ayant un nombre de vues $N = 1$ et le format *GRD* qui est un format multi-vues caractérisé par un nombre de vues variant de 4 à 9 vues, $N = 4, 5, 6, 7, 8, 9$. Dans ces travaux, nous avons utilisé uniquement le type de format *GRD* d'image Sentinel-1.

Mesure radar : coefficient de rétrodiffusion σ^o et valeur γ^o associée

Dans le cas de la mesure radar, on s'intéresse à l'interaction de l'onde émise avec les éléments du sol. Une partie de l'énergie électromagnétique envoyée par l'antenne radar est réfléchiée dans toutes les directions du demi-espace supérieur et la mesure concerne l'énergie renvoyée vers le capteur radar dans la direction inverse de la direction de visée. Cette puissance moyenne renvoyée par un pixel au sol vers l'antenne de réception est appelée puissance rétrodiffusée. Les calculs (<https://rus-training.eu/course> séquences *SAR-01* et *SAR-06*) montrent que la puissance rétrodiffusée vers l'antenne (moyennée localement pour éliminer les effets du chatoiement) peut s'écrire :

$$\langle P \rangle = K \cdot \sigma^o \cdot S_{\text{pixel_sol}}, \quad (2.11)$$

avec K une valeur que l'on peut considérer comme constante sur une portion d'image. K dépend de la puissance émise par l'antenne, des caractéristiques de l'antenne et de la géométrie d'acquisition, σ^o le coefficient de rétrodiffusion de la surface considérée. σ^o dépend de la nature de la surface, de son état et de l'angle d'incidence locale, et $S_{\text{pixel_sol}}$ la surface du pixel au sol.

La calibration des données que nous évoquerons dans la section 5.3.1 du Chapitre 5 permet de déduire la valeur du coefficient de rétrodiffusion σ^o de la puissance reçue en connaissant les conditions d'acquisition et les caractéristiques de l'antenne. Effectuer une calibration en γ^o est indiqué avec les images Sentinel-1 puisque l'incidence varie fortement au sein de la fauchée (entre 25° et 45° pour un terrain plat). Au niveau de la calibration, nous avons convenu d'effectuer l'opération en supposant le terrain plat, ce qui conduit à des évaluations des coefficients faussés lorsque la pente du terrain n'est pas nulle. En effet, nous avons de manière approchée (PAQUERAULT, 1998) :

$$\Delta S_{\text{sol_pente_p}} = \Delta S_{\text{sol_plat}} (\sin(\theta - p) / \sin(\theta)). \quad (2.12)$$

Ce qui conduit à :

$$\sigma^o_{\text{calibre_sol_plat}} = \sigma^o_{\text{reel}} (\sin(\theta) / \sin(\theta - p)) \quad \text{pour } \sigma^o, \quad (2.13)$$

$$\gamma^o_{\text{calibre_sol_plat}} = \gamma^o_{\text{reel}} (\tan(\theta) / \tan(\theta - p)) \quad \text{pour } \gamma^o p. \quad (2.14)$$

Ce qui entraîne la conclusion selon laquelle les effets de pente restent très présents dans les images calibrées. En pratique, on convertit souvent les valeurs de mesure en *décibels* selon la relation :

$$\gamma^o_{dB} = 10 \cdot \log_{10}, \quad (2.15)$$

avec γ^o en valeur naturelle.

La conversion en décibels permet de comprimer les valeurs en étalant la dynamique des valeurs les plus faibles et en comprimant les valeurs élevées, ce qui facilite en général l'interprétation des images.

2.2 Des images vers la carte

L'acquisition de séries temporelles sur de grandes étendues par les satellites imageurs permet l'étude de l'OCS à une échelle globale. Dans cette partie, les méthodes mises en place pour produire des cartes d'OCS à partir d'images satellitaires sont décrites. L'objectif n'est pas de proposer une liste exhaustive, mais plutôt de mettre en perspective les différentes approches de production.

Afin de produire une carte d'OCS, deux stratégies sont possibles. La première consiste à mettre à jour d'anciennes cartes d'OCS en identifiant les zones de changement ou les zones incomplètes, tandis que la seconde consiste à générer une nouvelle carte. La stratégie de mise à jour est moins courante. En effet, elle est attrayante sur le plan opérationnel et économique lorsque seules les zones de changement sont à analyser. Cependant, la reconnaissance de ces zones à mettre à jour est une question complexe, particulièrement dans des régions très hétérogènes avec des dynamiques temporelles fortes. Actuellement, les méthodes de détection de changement identifient trop de faux positifs, *i.e.* des zones à mettre à jour alors qu'aucun changement n'a eu lieu (GRESSIN, 2014). La généralisation de telles méthodes pour de grandes étendues est donc difficile, et a peu été exploitée. À titre d'exemple la *BDs* d'OCS à grande échelle *OCS-GE* produite par l'IGN prend le parti de fusionner des données existantes. Des traitements sont ensuite appliqués afin de respecter les spécifications de l'*OCS-GE*.

Quelque soit la stratégie choisie (mise à jour ou nouvelle carte), la production peut être réalisée soit manuellement, soit automatiquement. Ces deux types d'approches sont détaillés dans la suite avec une définition plus précise, des exemples de cartes ainsi que les avantages et inconvénients. Les cartes présentées sont décrites en termes de nomenclature (*e.g.* nombre de classes d'OCS), de résolution spatiale, de surface couverte, de temps de production et de mise à jour.

2.2.1 Approches manuelles

Les approches manuelles désignent ici toutes les approches nécessitant une forte intervention humaine pour la production des cartes. Trois sous-groupes d'approches sont distingués :

1. La photo-interprétation : des opérateurs externes, généralement experts en système d'information géographique *SIG* ou du terrain d'étude, identifient les *OCS* à l'aide d'images aériennes et satellitaires.
2. Les enquêtes terrain : des experts référencent les *OCS* en allant sur le terrain.
3. La production collaborative (« crowd-sourcing » en anglais) : des personnes bénévoles – pas nécessairement expertes en géomatique, en cartographie ou du terrain d'étude – contribuent à la cartographie de toutes les surfaces émergées à travers notamment les plateformes Internet *SIG* dédiées à la cartographie.

La photo-interprétation est entièrement basée sur l'utilisation des images satellitaires, tandis que les enquêtes terrain ou les approches collaboratives utilisent souvent l'image satellitaire en support avec d'autres technologies notamment le « web-mapping » et le géo-positionnement par satellite.

2.2.1.1 Photo-interprétation

Parmi les cartes produites par photo-interprétation, *CORINE* (*Coordination of Information on the Environment*) *Land Cover* (*CLC*) (faisant également intervenir un traitement d'images) est celle qui couvre le plus grand territoire : elle s'étend sur 39 pays européens. Cet inventaire est produit à partir

d'images satellitaires d'une résolution de 20 à 25 mètres dans le cadre du programme Copernicus et de la directive européenne « infrastructure d'information géographique dans la communauté européenne » (*Infrastructure for Spatial Information in the European Community (INSPIRE)*), pilotée par l'agence européenne pour l'environnement (*European Environment Agency (EEA)*). La nomenclature utilisée est hiérarchique et emboîtée² sur trois niveaux, et décrit un total de 44 classes. Au total quatre versions sont disponibles – 1990, 2000, 2006 et 2012 (BÜTTNER, 2014). La Figure 2.9 montre la version 2012 pour l'ensemble de l'Europe dont un zoom sur la ville de Toulouse est présenté à la Figure 1.3B du Chapitre 1. Des cartes de changement d'OCS entre versions sont aussi disponibles. Elles permettent des analyses simplifiées de l'évolution des territoires européens.

Le premier niveau de la nomenclature CLC est aussi utilisé pour la production des cinq couches thématiques hautes résolutions (*High Resolution Layers (HRL)*) : surfaces imperméables, prairies, forêt, surfaces en eau et zones humides. Les HRL sont produites par une approche de mise à jour, *i.e.* par fusion d'anciennes BDs, combinée avec la photo-interprétation et aussi une extraction automatique d'information (approches mixtes). La Figure 2.10 montre les couches de forêts (*en vert*) et de surfaces imperméables (*en rouge*) à l'ouest de l'Europe. Produite de manière similaire, les données Urban Atlas fournies aussi par l'EEA décrivent l'OCS pour 305 métropoles européennes de plus de 100 000 habitants et leurs alentours. Un exemple est donné par la Figure 1.3C au Chapitre 1.

L'Unité Minimale de Collecte (UMC) de 25 hectares fait de CLC une BDs³ idéale pour des statistiques nationales, mais inadaptées à des échelles plus fines comme la commune. Ainsi, des organismes régionaux ont produit leurs propres cartes d'OCS par photo-interprétation. Les projets CIGAL, SIGALE, OCSOL, Provence-Alpes-Côte d'Azur (PACA) et Mode d'Occupation des Sols (MOS) proposent des cartes d'OCS régionales en Alsace, Nord-Pas-de-Calais, PACA et en Île de France, respectivement. Par exemple, CIGAL se base sur des images SPOT-5 et des ortho-photographies de la BD *Ortho* de l'IGN pour obtenir une carte avec une UMC de 0,5 hectare décrivant 55 classes thématiques.

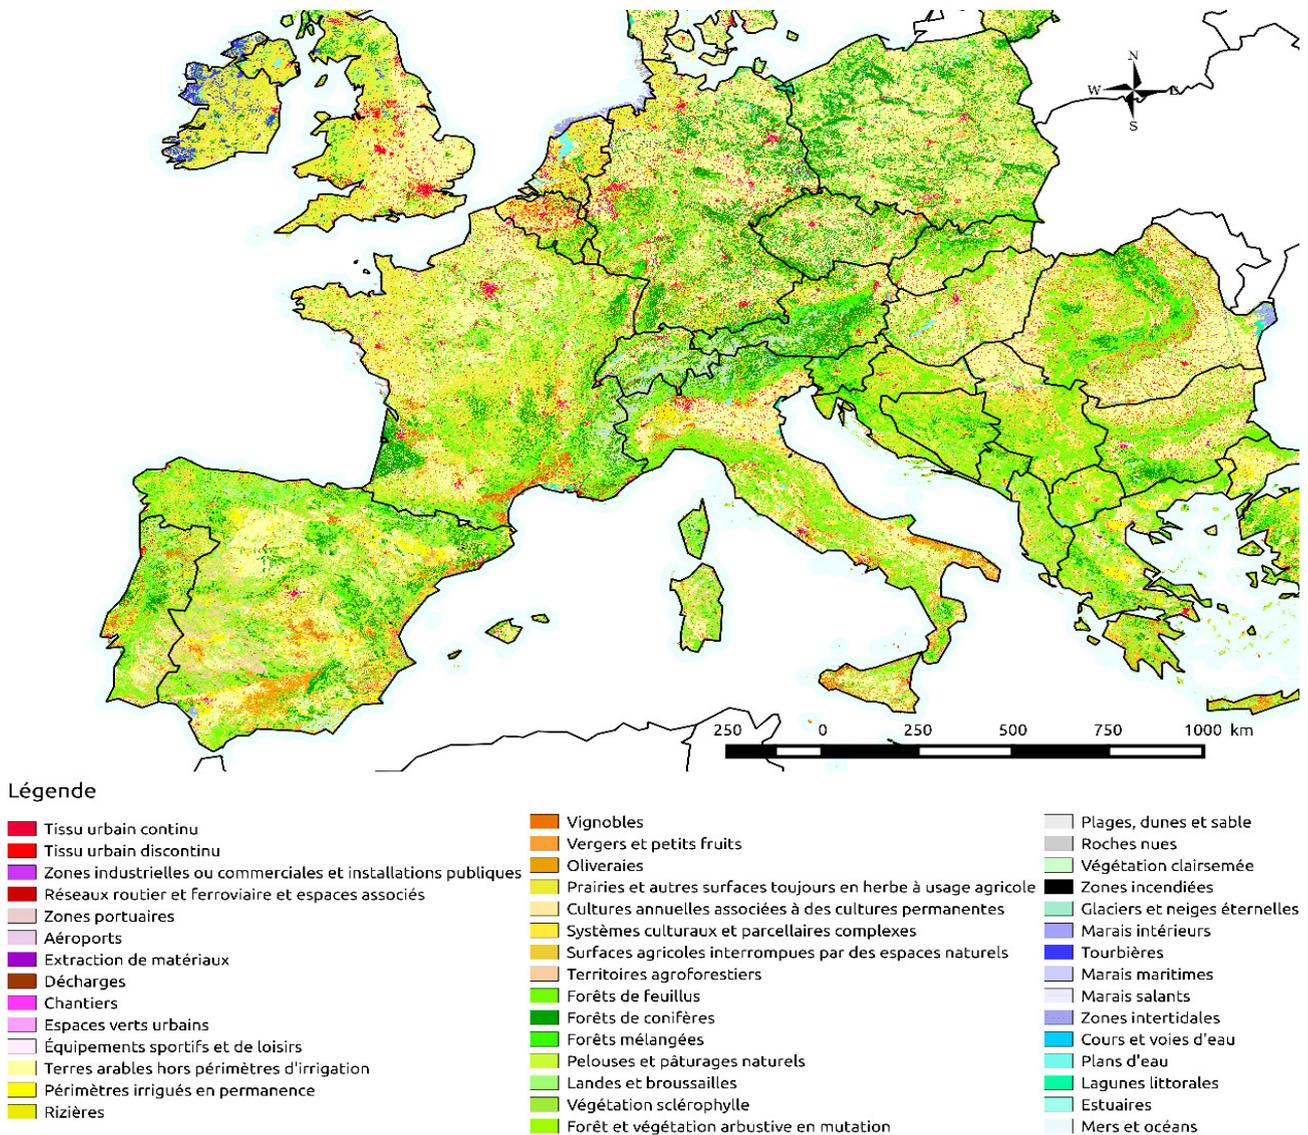
La génération de ces cartes par photo-interprétation a pour principal inconvénient des temps de production et de mise à jour très longs. Par exemple, la version 2012 de CLC a été mise à disposition seulement en 2015, et le temps de mise à jour est de six années entre les dernières versions. De plus, ces données sont coûteuses à produire, et l'expérience inégale entre les opérateurs engendre des hétérogénéités spatiales. Finalement, la qualité des cartes produites repose essentiellement sur les images satellitaires utilisées pour la photo-interprétation. Les opérateurs n'ayant pas le temps d'analyser l'ensemble des images acquises aux différentes dates, leur décision repose bien souvent sur seulement quelques images dont le contenu peut être insuffisant pour discriminer les classes d'OCS comme les cultures. Par ailleurs, la nomenclature CLC mélange occupation et usage des sols, ce qui peut poser problème à certains utilisateurs qui ont besoin seulement de l'OCS. Ces données sont tout de même de très bonne qualité grâce aux procédures rigoureuses d'identification.

2.2.1.2 Enquête terrain

Une autre approche manuelle pour produire des cartes sur de grandes étendues est d'effectuer une interpolation sur des relevés ponctuels issus d'enquêtes terrain. Par exemple, pour l'UTILISATION des

2. Une nomenclature hiérarchique emboîtée est une nomenclature qui s'étend sur plusieurs niveaux. Par exemple, une classe surface en eau pourra être décrite plus finement en deux sous classes comme eaux continentales et eaux maritimes.

3. Le terme BDs fait ici référence à la BDs géographiques pour laquelle il est possible de dériver une carte d'OCS, *i.e.* une prise de vue de la BDs. Par exemple, la BDs *BD Topo* de l'IGN contient plusieurs couches thématiques pour lesquelles il est possible de construire différentes cartes d'OCS en fonction de ces besoins.

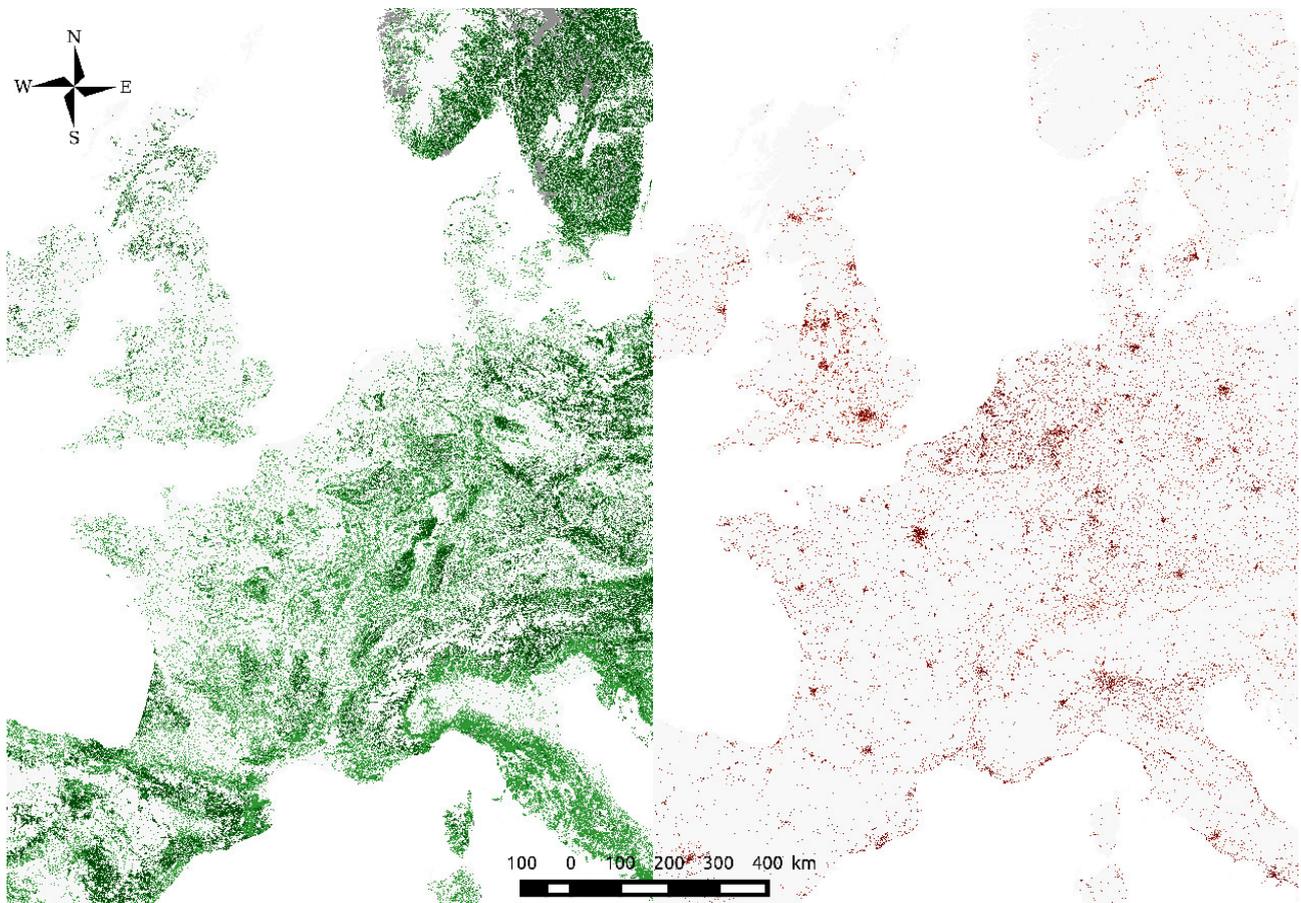


Source : amcarto.alwaysdata.net/demo/test/{compa_ocs}.html

FIG. 2.9 – CORINE Land Cover 2012.

TERritoires (*Teruti-Lucas*) (*Land Use/Cover Area frame statistical Survey*) – géré en France par Agreste, le service statistique du ministère de l'Agriculture – les enquêteurs identifient l'OCS sur deux niveaux : 1) le segment, *i.e.* une portion du territoire homogène d'environ $1,5 \text{ km}^2$, et 2) le point, *i.e.* un cercle de 3 ou 40 mètres de diamètre. L'image satellitaire, plus spécifiquement des ortho-photographies, est seulement utilisée pour le géo-référencement.

Outre les problèmes d'exhaustivité, les relevés terrain nécessitent souvent plusieurs passages des enquêteurs notamment pour la végétation. Par exemple, les cultures d'été et les cultures d'hiver ne peuvent pas être discriminées à la même période. Ainsi l'enquêteur doit effectuer trois à quatre passages pour être rigoureux, ce qui augmente le coût et le temps de production.



Source : amcarto.alwaysdata.net/demo/test/{compa_ocs}.html

FIG. 2.10 – *High Resolution Layers 2012*. Couche forêts à gauche, couche surfaces imperméables à droite.

2.2.1.3 Crowd-sourcing

Le dernier type d'approche manuelle consiste à faire intervenir des contributeurs non-experts en cartographie. En effet, la démocratisation des SIG en ligne et des GPS ont conduit à l'émergence de « la cartographie 2.0 ». Créé en 2004, *OpenStreetMap (OSM)*⁴ a pour objectif de produire une carte mondiale librement modifiable et accessible. C'est le projet d'information géographique bénévole (« *volunteered geographic information* » en anglais) le plus abouti actuellement (Figure 1.3D, Chapitre 1). Tous les citoyens peuvent contribuer en utilisant des images aériennes – assez rares, car les images ne doivent pas être sous *Copyright* – des traces de géo-positionnement par satellite (*Global Positioning System (GPS)*) ou des panoramas à 360 degrés acquis par exemple par la caméra *OpenStreetCam*⁵ (NEIS et ZIELSTRA, 2014). Sur un principe similaire, *WikiMapia*⁶ propose aux internautes de cartographier les sols à partir de *Google Maps* depuis 2006. L'utilisation de plateformes collaboratives permet aussi de remonter dans le temps. Par exemple, le projet national *GeoHistoricalData*⁷ cartographie des sources historiques comme la carte de Cassini datant de la fin du XVIII^e siècle.

4. openstreetmap.org

5. OpenStreetCam.org

6. wikimapia.org

7. GeoHistoricalData.herokuapp.com

Le « crowd-sourcing » a aussi été utilisé afin d'améliorer des cartes existantes. La carte *GeoWiki* a été en partie réalisée à l'aide d'outils collaboratifs pour mettre à jour les cartes *Global Land Cover (GLC) 2000*, *Collection 5 MODIS Land Cover Type Product (MCD12Q1) 2005* et *GlobCover 2005* produites automatiquement (et décrites après) (FRITZ et al., 2009; FRITZ et al., 2012; SEE et al., 2015).

Les avantages de ces données collaboratives sont le faible coût de production⁸ et la possibilité de remonter dans le temps. Cependant, les personnes non-expertes en SIG et du terrain d'étude sont généralement moins précises et rigoureuses dans leurs déclarations, ce qui conduit à de nombreuses incohérences et confusions dans les données répertoriées. Des contributeurs bénévoles en désaccord fournissent alors des informations contradictoires (JOHNSON et IIZUKA, 2016). Ainsi, les précisions des données peuvent être faibles : 76 % pour le Portugal (ESTIMA et PAINHO, 2013) et 64 % pour Hambourg (ARSANJANI et al., 2015) pour OSM. Par ailleurs, rien ne garantit la complétion de ces données puisque les contributeurs choisissent les zones qu'ils cartographient.

De manière générale, toutes les approches manuelles sont dépendantes des opérateurs, des experts et des contributeurs qui construisent la carte. Ainsi, la reproductibilité et la continuité des produits ne sont pas assurées, les coûts de production sont élevés, et surtout les temps de mise à jour sont longs.

2.2.2 Approches automatiques

Contrairement aux approches manuelles, les approches automatiques visent à extraire l'OCS à partir d'images principalement aéroportées et satellitaires en limitant l'intervention humaine. Pour ce faire, des méthodes de classification sont utilisées : chaque pixel de l'image est associé à une classe d'OCS. Ces méthodes sont fondées sur le principe de l'apprentissage automatique (« *machine learning* » en anglais). Traditionnellement, deux approches sont distinguées : supervisée et non-supervisée.

La Figure 2.11 montre la différence entre ces deux approches qui réside principalement dans l'utilisation faite de la donnée de référence. Dans le cas d'un apprentissage supervisé, la donnée de référence donne une connaissance a priori sur l'OCS. Elle permet d'obtenir des échantillons d'apprentissage pour lesquels l'OCS est connue, et qui seront ensuite utilisés par l'algorithme de classification supervisée. Ainsi, les échantillons d'apprentissage jouent un rôle essentiel dans la précision du résultat final : ils doivent représenter précisément chacune des classes et caractériser la variabilité de la zone étudiée. De plus, la donnée de référence doit dater de la même année que les images à classer pour éviter des erreurs liées aux changements d'OCS entre années, *e.g.* la rotation des cultures ou l'expansion de zones péri-urbaines. Dans le cas d'un apprentissage non-supervisé, les pixels de l'image sont regroupés par similarité (*clustering* »), et les classes sont ensuite déterminées.

Une des premières BDs mondiales d'OCS produite automatiquement est la donnée *DISCover (Data and Information System Cover)* issue des données *GLCC (Global Land Cover Characterization) 2.0*⁹. Elle décrit 17 classes définies par le programme international pour la géosphère et la biosphère (*International Geosphere-Biosphere Program*) (IGBP) ou à une résolution spatiale kilométrique (BELWARD, ESTES et KLINE, 1999; LOVELAND et al., 2000; LOVELAND et al., 2009; SCEPAN, 1999). Elle est obtenue par un apprentissage non-supervisé sur des images de l'agence américaine d'observation océanique et atmosphérique (*National Oceanic and Atmospheric Administration (NOAA)*) ou acquises par le capteur

8. Le coût de production s'entend ici d'un point de vue économique. Il est bien entendu que le coût investi par les différents contributeurs bénévoles est important, même s'il ne fait pas l'objet d'une transaction financière.

9. lta.cr.usgs.gov/glcc/globdoc2_0

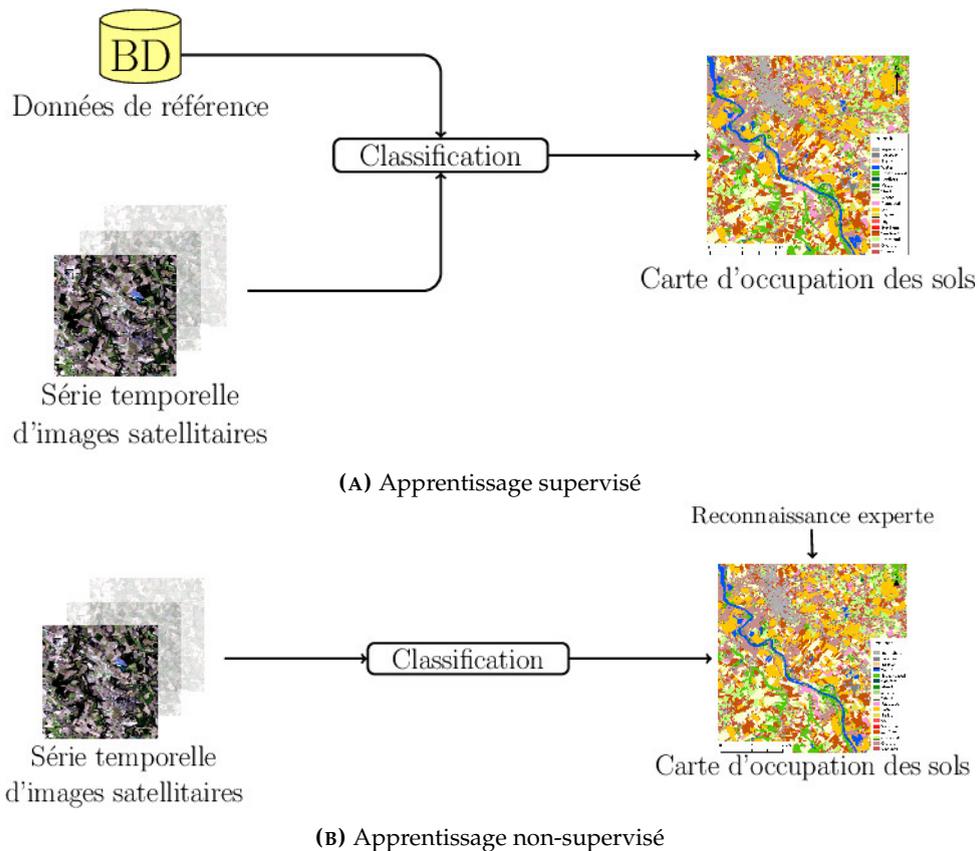


FIG. 2.11 – Schémas simplifiés des apprentissages supervisé et non-supervisé pour la cartographie de l'OCS.

AVHRR entre 1992 et 1993. La carte de l'Université du Maryland UMD est produite par un apprentissage supervisé pour les mêmes images mais avec une nomenclature IGBP simplifiée à 12 classes (HANSEN et al., 2000). La carte GLC 2000 de l'organisation des Nations unies pour l'alimentation et l'agriculture (*Food and Agriculture Organization of the United Nations (FAO)*), aussi à un kilomètre de résolution, décrit 22 classes définies par le LCCS (*Land Cover Classification System*). (BARTHOLOMÉ et BELWARD, 2005). La carte est obtenue par apprentissage non-supervisé à partir d'images acquises par le capteur VEGETATION du satellite SPOT-4.

L'arrivée des capteurs MERIS (*Medium Resolution Imaging Spectrometer*) et le radiomètre spectral pour imagerie de résolution moyenne (*Moderate Resolution Imaging Spectroradiometer (MODIS)*) a conduit aux développements de cartes à une résolution spatiale entre 250 et 500 mètres. Par exemple, les cartes MCD12Q1, produites annuellement depuis 2001 à partir de méthodes supervisées, décrivent 17 classes IGBP à 500 mètres de résolution spatiale (FRIEDL et al., 2010). Les cartes GlobCover, GLCNMO et GLC250 aussi produites dans les années 2000 présentent des caractéristiques similaires (ARINO et al., 2007; BONTEMPS et al., 2015; DEFOURNY et al., 2006); (TATEISHI et al., 2014); (WANG et al., 2015). Les produits CCI-LC (*Climate Change Initiative - Land Cover*) 2000, 2005 et 2010 de l'ESA à 300 mètres de résolution fournissent en plus des cartes de la couverture des sols, une estimation sur les changements d'OCS à une résolution kilométrique en s'appuyant sur des images acquises par le capteur AVHRR.

Depuis la mise à disposition gratuite des images Landsat-7 et -8, des cartes d'OCS mondiales à une résolution de 30 mètres ont été produites. Par exemple, les cartes FROM-GLC et GlobeLand30,

produites par les organismes chinois CESSC (*Centre for Earth System Science China*) et NASG (*National Administration of Surveying, Mapping and Geoinformation*), décrivent une dizaine de classes (CHEN et al., 2015b; GONG et al., 2013; YU et al., 2013a; YU, WANG et GONG, 2013b).

La mise en orbite des deux satellites Sentinel-2 doit permettre la production de cartes à 10 mètres de résolution. Pour le moment, une carte annuelle de la France a été produite au Centre d'Études Spatiales de la BIOSphère (CESBIO) et mise à disposition depuis 2017 (Figure 1.2). L'approche entièrement automatique s'appuie sur l'apprentissage supervisé d'une série temporelle d'images Sentinel-2 annuelle. Elle est équivalente à celle utilisée pour la création de la carte 2013 produite à 30 mètres à l'aide d'images Landsat-8 (Figure 1.3F, Chapitre 1) (INGLADA et al., 2017a).

La description de ces différentes cartes montre que les approches non-supervisées ont été délaissées au profit des méthodes supervisées (FRANKLIN et WULDER, 2002; KHATAMI, MOUNTRAKIS et STEHMAN, 2016). Les deux principales raisons sont la mise à disposition de données facilitant la collecte d'échantillons d'apprentissage et la meilleure précision des algorithmes supervisés (GREKOUSIS, MOUNTRAKIS et KAVOURAS, 2015).

Dans un contexte opérationnel, la majorité des méthodes utilise de manière inadéquate ou sous-optimale l'information temporelle contenue dans les séries d'images satellitaires. Par exemple, certains travaux sélectionnent des dates clés représentant des stades phénologiques discriminatifs. Afin de discriminer au mieux les cultures d'hiver des cultures d'été, il est courant de sélectionner des images peu nuageuses acquises à deux saisons différentes (RODRIGUEZ-GALIANO et al., 2012b; ROGAN, FRNAKLIN et ROBERTS, 2002). Ces dates clés fournissent généralement des images comprenant de fortes différences dans les signatures spectrales de la végétation. Cependant, cette sélection subjective peut conduire à une faible précision globale (64,89 % par exemple pour *FROM-GLC* (GONG et al., 2013)). En outre, cette sélection de dates clés, est une étape complexe. D'une part, les acquisitions (non-nuageuses) d'images satellitaires ne sont pas assurées aux dates clés. D'autre part, le changement climatique ainsi que l'activité anthropique modifient les OCS, et peuvent donc modifier les dates clés d'une année sur l'autre.

Par ailleurs, les traitements sur de grandes étendues sont réalisés pour des raisons pratiques par tuile, *i.e.* une zone d'étude est découpée en zones rectangulaires sur lesquelles une série de traitements identique est appliquée. Dans le cadre d'une sélection de dates clés par tuile, les traitements peuvent conduire à la présence d'artefacts et de démarcations à la jonction entre les tuiles. Cet effet de bord diminue la qualité du résultat final. Pour toutes ces raisons, la sélection de dates clés n'est pas adaptée à la mise en place d'une chaîne de traitement automatique.

Une autre approche couramment utilisée consiste à combiner des images sur plusieurs années sans prendre en compte les évolutions du paysage. Par exemple, les cartes *FROM-GLC* et *GlobeLand30* utilisent des images Landsat-5 -7 et -8 acquises sur une quinzaine d'années (1984 à 2011). Sur une telle période, l'urbanisation, l'expansion des zones agricoles ou encore la déforestation modifient fortement les paysages. D'une part, l'interprétation de la carte produite est difficile car il est impossible de déterminer à quelle année appartiennent les résultats. D'autre part, les échantillons d'apprentissage utilisés doivent être caractérisés par une seule OCS qu'il est difficile de définir si les OCS changent d'une année sur l'autre.

Pour obtenir des données de référence de qualité, les collectes sont généralement effectuées par photo-interprétation. Comme cette collecte est longue, la mise à jour fréquente des cartes est difficile.

Seule la donnée *MCD12Q1* fournit des cartes annuellement en photo-interprétant régulièrement des images *MODIS* pour 1860 sites stratifiés par régions éco-climatiques sur l'ensemble du globe (FRIEDL et al., 2010). La basse résolution spatiale de 250 mètres des images *MODIS* permet d'avoir un faible nombre de zones à photo-interpréter, et donc une mise à jour annuelle qu'il ne serait pas possible de maintenir avec des images à une résolution spatiale de 10 mètres. Cependant, plusieurs *OCS* sont présentes dans des pixels de 250 mètres \times 250 mètres.

Pour les cartes produites à 30 mètres, comme *FROM-GLC* et *GlobaLand30*, des profils temporels *MODIS* à 500 mètres en complément des images Landsat-8 sont aussi utilisés pour la photo-interprétation des échantillons d'apprentissage. L'utilisation de profils temporels à basse résolution conduit à diminuer la résolution effective de la carte finale (BROXTON et al., 2014). De plus, l'utilisation de la photo-interprétation limite la quantité de données de référence extraite. Or, la classification sur de grandes étendues nécessite un nombre conséquent d'échantillons bien répartis spatialement pour assurer une bonne représentation de la zone. Ainsi, (INGLADA et al., 2017a) utilisent d'anciennes cartes comme référence. Cependant, l'utilisation de données obsolètes conduit à des incertitudes sur l'information fournie à l'algorithme de classification, notamment pour les **classes de végétation** qui évoluent annuellement, qui potentiellement diminue la précision de la carte produite.

2.3 Classification supervisée de séries temporelles

Dans le contexte de la cartographie de l'*OCS*, de nombreuses méthodes ont été proposées pour la classification des données satellitaires. Cependant, peu d'études se focalisent sur la classification de séries temporelles d'images satellitaires optiques. Ce manque d'études s'explique par la récente disponibilité des séries temporelles optiques à haute résolution spatiale.

Pour la classification de séries temporelles, les premiers travaux ont été menés en utilisant principalement des approches paramétriques comme le maximum de vraisemblance, le modèle de mélanges gaussiens (*Gaussian Mixture Model*, *GMM*) ou encore l'analyse discriminante. Ces méthodes font une hypothèse sur la nature du modèle dont les paramètres sont estimés à l'aide des échantillons d'apprentissage. Elles ont été utilisées plusieurs fois pour la classification de séries temporelles à basse résolution spatiale (*MODIS*, *MERIS*, et *AVHRR*) (DEFRIES et TOWNSHEND, 1994; JIA et al., 2014b; RADOUX et al., 2014).

La majorité des méthodes paramétriques suppose que la distribution des variables décrivant les échantillons appartenant à une même classe suit une loi normale, ce qui est rarement le cas dans le contexte de la classification de séries temporelles. Ainsi, ces approches échouent à prendre en compte les différentes apparences de certaines classes, et les variations spectro-temporelles présentes dans les séries temporelles. Les frontières obtenues entre les classes sont incorrectes (HUBERT-MOY et al., 2001).

Pour ces raisons, les méthodes non-paramétriques sont plus efficaces que les méthodes paramétriques lorsque les distributions des classes d'*OCS* sont inconnues (FOODY et MATHUR, 2006). Parmi ces approches, le réseau de neurones artificiels (*Artificial Neural Network* (*ANN*)) est une méthode précise (GOPAL, WOODCOCK et STRAHLER, 1999; MAS et FLORES, 2007), mais qui requiert la configuration de nombreux paramètres (nombre de neurones et nombre de couches). L'optimisation de ces paramètres a tendance à conduire au sur-apprentissage (RODRIGUEZ-GALIANO et al., 2012b). Par ailleurs, le modèle construit par l'*ANN* est une boîte noire puisque les règles de décision apprises par le modèle sont difficiles à analyser et interpréter.

D'autres méthodes non-paramétriques récentes concernent les approches par apprentissage profond comme les réseaux convolutifs temporels (*Temporal Convolutional Neural Networks (TempCNNs)*). Le réseau de neurones convolutifs temporels *TempCNNs* est une approche standard d'apprentissage profond qui applique des convolutions dans la dimension temporelle pour apprendre automatiquement les caractéristiques temporelles (et spectrales). Par conséquent, cette méthode est particulièrement adaptée aux données temporelles. (PELLETIER, WEBB et PETITJEAN, 2019) utilisent 46 images du satellite Formosat-2 et un million de séries temporelles étiquetées pour évaluer quantitativement et qualitativement la contribution des *TempCNNs* par rapport au *RF* et au réseau de neurones récurrents (*RNNs*) et montrer que les *TempCNNs* sont plus précis que les approches de l'état de l'art pour la classification de séries temporelles d'images satellitaires.

Par ailleurs, (GARNOT et LANDRIEU, 2021) s'appuient sur la technique de l'auto-encodage temporelle en mettant de bout en bout les résultats issus des auto-encodeurs pour extraire des caractéristiques spatio-temporelles multi-échelles riches et adaptatives et démontrer la supériorité du premier auto-encodeur temporelle pour la segmentation panoptique de séries temporelles d'images satellitaires face à de multiples autres architectures concurrentes.

De plus, la grande quantité de données actuellement produites par les missions modernes d'observation de la Terre a permis la conception de techniques avancées d'apprentissage automatique capables de prendre en charge des tâches complexes de la cartographie de l'OCS. Le programme *Copernicus* développé par l'ESA fournit des images radar et optiques (multi-spectrales) à une résolution spatiale de 10 mètres avec un temps de revisite d'environ 5 jours avec des missions des satellites Sentinel-1 (S-1) et Sentinel-2 (S-2) respectivement. Une résolution temporelle aussi élevée permet de collecter des séries temporelles d'images satellitaires qui prennent en charge plusieurs tâches de surveillance de la surface de la Terre. Comment combiner efficacement les informations complémentaires fournies par de tels capteurs reste un problème majeur dans le domaine de la télédétection. Ainsi, (IENCO et al., September 2019) proposent une architecture d'apprentissage profond pour combiner les informations provenant des séries temporelles S-1 et S-2 à savoir *TWIn Neural Networks for Sentinel data*, capable de découvrir les dépendances spatiales et temporelles dans les deux types d'images. Cette architecture exploite le processus de classification de l'OCS de deux zones d'étude présentant des caractéristiques très différentes (Koumbia au Burkina Faso et l'île de La Réunion) en tirant parti de deux niveaux de complémentarité à savoir l'interaction entre les images optique et radar ainsi que la synergie entre leurs dépendances spatiales et temporelles.

Une autre approche non-paramétrique couramment utilisée est le *Support Vector Machine (SVM)* (MOUNTRAKIS, IM et OGOLE, 2011). Il a été appliqué avec succès pour la classification de séries temporelles optiques (CARRÃO, GONÇALVES et CAETANO, 2008; DASH et al., 2007; HUANG, DAVIS et TOWNSHEND, 2002a; JIA et al., 2014b). De plus, il présente de nombreux avantages et de bonnes performances lorsque le nombre de variables est grand devant le nombre d'échantillons d'apprentissage (PAL, 2005). Afin de traiter des problèmes complexes, le *SVM* utilise souvent une fonction noyau qui nécessitera la configuration non triviale de paramètres supplémentaires (MÜLLER et al., 2001).

Ainsi, les arbres de décision binaire plus faciles à paramétrer ont été utilisés pour la cartographie de séries temporelles Landsat (DASH et al., 2007; GEBHARDT et al., 2014), et pour les cartes *MCD12Q1* à partir d'images *MODIS* (FRIEDL et al., 2010). Rapides à entraîner, ils permettent en plus d'utiliser des variables de différentes natures (réflectance, indices normalisés, etc.). Cependant, leurs performances

sont en-deçà de celles des *ANN* et *SVM* dans les espaces à grande dimension (HANSEN, Taylor & Francis, 2012). Et comme les modèles *ANN*, ils ont tendance à faire du sur-apprentissage (GHIMIRE et al., 2012).

Chaque algorithme décrit précédemment a ses propres avantages et inconvénients et conduit à des résultats différents sur les mêmes données. Les méthodes d'ensemble cherchent alors à combiner différents algorithmes de classification pour tirer bénéfice de chacun d'entre-eux (DIETTERICH, 2000a). Ces méthodes ont une variance moins importante que la variance individuelle des algorithmes de classification puisque la sensibilité aux données d'apprentissage est diluée entre tous les algorithmes. Pour autant, le biais n'est pas augmenté par rapport à celui de chaque algorithme. Ainsi, ces méthodes sont moins sensibles aux données d'entrée et plus robustes au bruit (FOODY et al., 2016; JOHNSON et IIZUKA, 2016). De plus, les performances de classification sont améliorées (BAUER et KOHAVI, 1999), notamment pour la classification de données multi-capteurs et multi-temporelles (BRIEM, BENEDIKTSSON et SVEINSSON, 2002; DU et al., 2012; MIAO et al., 2012).

Parmi les méthodes d'ensemble, la forêt aléatoire (*Random Forest (RF)*) construit un ensemble d'arbres de décision binaire (BREIMAN, 2001). Dans le cadre de la cartographie de l'OCS, le nombre de travaux utilisant le *RF* ne cesse d'augmenter (GISLASON, BENEDIKTSSON et SVEINSSON, 2006a; INGLADA et al., 2017a; PAL, 2005; RODRIGUEZ-GALIANO et al., 2012b). Outre ses performances comparables avec d'autres algorithmes de classification (BELGIU et DRĂGUȚ, 2016), le *RF* présente de nombreux avantages : un temps de calcul réduit dû à la possibilité de construire les arbres en parallèle (LASSALLE et al., 2015), la possibilité de prendre en entrée des gros volumes de données et en particulier un nombre élevé de variables, et une facilité d'interprétation offerte par la visualisation des arbres¹⁰.

2.4 Choix de l'algorithme de classification supervisée

Il existe dans la littérature plusieurs centaines d'algorithmes de classification développés pour de nombreux domaines d'application (FERNÁNDEZ-DELGADO et al., 2014). Chaque algorithme de classification a ses propres avantages et inconvénients, et leur performance dépend des jeux de données étudiés (CARUANA et NICULESCU-MIZIL, 2006).

Le contexte de ces travaux est lié à la mise en place d'une chaîne de traitement automatique pour la production de cartes d'OCS sur de grandes étendues à partir de séries temporelles d'images satellitaires comme celles fournies par Sentinel-2. Plusieurs classifieurs ont déjà été utilisés pour la classification de séries temporelles. Afin de sélectionner les plus appropriés, les critères suivants sont importants : 1) la précision, 2) le temps de calcul, 3) le paramétrage, 4) la stabilité, et 5) la robustesse.

Un des principaux inconvénients est le temps de production des méthodes actuelles. Bien que la carte produite doit être aussi précise que possible, un compromis est nécessaire avec les temps de calcul. Ces derniers dépendent des volumes de données à traiter, mais aussi de la complexité du modèle appris par les algorithmes de classification. Il est alors important de bien connaître le comportement des algorithmes de classification afin de déterminer le point de fonctionnement optimisant le compromis entre la précision et la complexité du modèle appris pour une application donnée, ici la classification de séries temporelles d'images satellitaires sur de grandes étendues.

10. Cette propriété est parfois remise en cause dans la littérature à cause du côté aléatoire introduit par les échantillons *bootstrap* et le principe du *random feature selection*. De plus, un nombre élevé d'arbres complique l'analyse des règles de décision pour l'ensemble des échantillons. Il n'en reste pas moins qu'il est possible de visualiser chaque arbre de la forêt, et donc de suivre chaque échantillon.

Dans un contexte d'automatisation des chaînes de traitement, il est aussi intéressant que les performances de l'algorithme de classification ne soient pas dépendantes d'un réglage très fin de ses paramètres. Cette propriété aura un double avantage. Le premier sera de réduire le temps dédié à l'optimisation des paramètres, et le second sera de pouvoir garder le même paramétrage pour analyser différentes zones d'études ou la même zone d'étude à différentes dates.

Un autre critère concerne la généralisation de l'algorithme de classification. L'algorithme ne doit pas trop s'adapter aux échantillons d'apprentissage, et être capable de prédire correctement l'étiquette de nouveaux échantillons. Dans le cas d'études sur de grandes étendues, l'algorithme de classification doit être donc capable de gérer d'une part les fortes variabilités intra-classes, *i.e.* les classes avec différentes apparences, et d'autre part les faibles variabilités inter-classes, *i.e.* les classes très similaires.

Finalement, il est intéressant que l'algorithme de classification soit robuste à la présence de données imparfaites dans les échantillons d'apprentissage. Dans le cas où un grand nombre de données de référence est nécessaire, cela permettrait d'autoriser l'utilisation de données de référence pour lesquelles certaines étiquettes sont incertaines.

Concernant la classification de séries temporelles d'images satellitaires, les revues récentes de (KHATAMI, MOUNTRAKIS et STEHMAN, 2016) et (GÓMEZ, WHITE et WULDER, 2016) soulignent les bonnes performances du *RF* et du *SVM* et ces résultats sont en accord avec les travaux de (GONG et al., 2013) dont les cartes *FROM-GLC* les plus précises sont obtenues avec le *RF* et le *SVM*. Par ailleurs, des études préliminaires réalisées au CESBIO montrent aussi le potentiel des deux algorithmes pour la classification de séries temporelles (INGLADA et al., 2015b).

Depuis quelques années, les méthodes d'apprentissage profond (« *deep learning* » en anglais) basées sur des réseaux neuronaux sont de plus en plus utilisées. Par exemple, l'algorithme très utilisé du réseau de neurones convolutif (*Convolutional Neural Network (CNN)*) ou a été appliqué avec succès sur des images satellitaires à très haute résolution spatiale (MAGGIORI et al., 2017; POSTADJIAN et al., 2017). Un des principaux avantages du *CNN* est de s'affranchir de l'extraction des variables pertinentes grâce aux différentes couches de convolution du réseau. Cependant, plusieurs limitations persistent pour la classification de séries temporelles à haute résolution spatiale : 1) le paramétrage (les nombre de couches et nombre de neurones) des réseaux est complexe, 2) un grand nombre d'échantillons d'apprentissage est requis, 3) des ressources informatiques importantes sont nécessaires, et 4) l'interprétation physique des résultats est impossible (boîte noire) à cause de la complexité des modèles produits (jusqu'à plusieurs millions de neurones).

Des approches dites de segmentation sémantique – *e.g.* les architectures de réseau de neurones entièrement convolutive (*SegNet*) et sa dérivée multi-modale (*UNet*) pour la segmentation sémantique d'images *RGB-D* – peuvent prédire plusieurs classes au sein d'une même vignette.

Afin de remédier aux temps d'apprentissage très longs des *CNN* et des besoins en vérité terrain, des réseaux de neurones pré-entraînés ont été mis à disposition. Ils ont permis de démocratiser l'utilisation du *CNN*. Dans ce cas là, les principaux paramètres du réseau sont déjà appris, et une étape peu coûteuse permet d'adapter le réseau à son problème de classification. Malheureusement, ces réseaux sont souvent pré-entraînés sur des images mono-dates *RVB*, et ne peuvent donc pas être directement appliqués sur des séries temporelles. L'atout des résolutions spectrales et temporelles ne peut donc pas être pleinement exploité. Finalement, la robustesse du *CNN* en présence de données mal étiquetées est inconnue puisque dans le domaine multimédia les images utilisées pour l'apprentissage sont toutes correctement étiquetées.

Le potentiel des réseaux de neurones profonds, comme le *CNN*, est indéniable mais nécessite encore des adaptations pour être appliqué de manière opérationnelle au problème de la classification de l'OCS¹¹. Ces adaptations ont été faites sur la France qui dispose de bonnes données d'apprentissage et le *CNN* y marche bien désormais de manière opérationnelle. Ces adaptations ne pourront pas être faites sur nos zones d'étude au Cameroun car ces dernières ne contiennent pas de bonnes données d'apprentissage. Pour toutes ces raisons, les réseaux de neurones profonds n'ont pas été abordés dans ces travaux. La suite de ce chapitre se focalise sur la description technique détaillée de l'algorithme du *RF* utilisé dans le cadre des travaux.

Étant donné que la production de cartes d'OCS sur de grandes étendues à partir de séries temporelles d'images nécessite d'utiliser un grand nombre de données de référence autorisant la prise en compte de données imparfaites dans les échantillons d'apprentissage, il est donc important que l'algorithme de classification soit robuste à la présence de données imparfaites dans les échantillons d'apprentissage. L'algorithme du *RF* a été identifié comme celle la plus appropriée dans cette thèse.

2.5 Algorithme de classification : *Random Forest*

L'objectif de cette partie est de présenter en détail l'algorithme du *RF* utilisé dans le cadre de ces travaux et dont les études préliminaires réalisées au CESBIO ont montré son potentiel pour la classification de séries temporelles (INGLADA et al., 2015b).

Le *RF* est un algorithme d'apprentissage supervisé fondé sur la technique de l'arbre de décision binaire. La particularité du *RF* est de combiner un ensemble d'arbres de décision binaire afin de construire sa règle de décision. Dans un premier temps, le principe des méthodes d'ensemble est décrit. Dans un deuxième temps, l'introduction des arbres de décision binaire est expliquée. Finalement, une dernière partie est dédiée au principe de fonctionnement du *RF*.

2.5.1 Méthodes d'ensemble

L'idée des méthodes d'ensembles est de combiner les prédictions de différents algorithmes de classification afin d'obtenir un classifieur plus performant (DIETTERICH, 2000a). L'utilisation des prédictions de plusieurs algorithmes de classification au lieu d'un seul permet notamment :

- d'améliorer la décision finale en s'appuyant sur les prédictions de plusieurs classifieurs ayant des comportements différents,
- d'obtenir un classifieur plus générique et moins enclin à proposer une solution sous-optimale,
- de traiter des problèmes complexes qui ne peuvent être résolus de manière optimale avec un seul algorithme de classification.

Il existe deux stratégies pour la construction de ces ensembles : 1) combiner différents algorithmes de classification, et 2) combiner différentes variantes d'un même algorithme de classification. Les sorties de chaque classifieur sont ensuite fusionnées, généralement par un **vote majoritaire** (ROKACH, 2010). L'intérêt des méthodes d'ensemble réside donc dans l'utilisation de classifieurs qui ont des comportements considérablement différents. Les différences de comportement entre classifieurs

11. Bien que les réseaux de neurones profonds ont remporté de nombreux concours dans le domaine du « *machine learning* » ces dernières années, on notera que la première place du « *Data Fusion Contest* » 2017 a été gagnée par une variante de l'algorithme du *RF* sur un problème de classification en milieu urbain avec des séries temporelles d'images satellitaires.

peuvent être quantifiées à travers la notion de diversité. Bien qu'il n'y ait pas de consensus dans la littérature sur la définition de la diversité, il est admis qu'une mesure élevée de diversité correspond à une méthode d'ensemble qui a de bonnes performances en prédiction (BROWN et al., 2005 ; KUNCHEVA et WHITAKER, 2003 ; MELLOR et BOUKIR, 2017). Cependant, l'utilisation de classifieurs qui ont des prédictions trop contradictoires, et donc une très grande mesure de diversité, résultera en un classifieur final de faible qualité (KAPP, SABOURIN et MAUPIN, 2007).

Un autre concept important des méthodes d'ensemble est la marge introduite par (SCHAPIRE et al., 1998). La marge supervisée (si notion de correct ou incorrect existe) est définie comme la différence entre le pourcentage de classifieurs votant correctement et le pourcentage de ceux votant incorrectement. Elle permet de fournir une mesure de confiance dans les méthodes d'ensemble (GUO, 2011 ; MELLOR et al., 2015). À noter que les concepts de diversité et de marge sont très liés puisqu'une majorité des définitions proposées pour la diversité sont fonction de la marge (STAPENHURST, 2012).

Dans la suite, trois techniques pour construire des méthodes d'ensemble à partir d'un même algorithme de classification sont décrites.

La première technique présentée est celle du *random subspace* (BRYLL, GUTIERREZ-OSUNA et QUEK, 2003 ; HO, 1998). Dans cette approche, la diversité est ajoutée en utilisant un sous-ensemble de variables tirées aléatoirement sans remise pour décrire les échantillons. En revanche, tous les échantillons sont utilisés pour apprendre l'ensemble des classifieurs. Ainsi, chaque classifieur est spécialisé pour un groupe de variables spécifiques. La combinaison des classifieurs permet alors d'obtenir un algorithme fiable sur tout l'espace des caractéristiques.

Les deux autres techniques présentées sont le *bagging* et le *boosting*. La diversité est ajoutée en jouant sur l'utilisation des échantillons d'apprentissage pour construire chaque classifieur.

Plus spécifiquement, le *bagging* (*bootstrap aggregating*) consiste à construire plusieurs classifieurs en s'appuyant sur des sous-ensembles d'échantillons d'apprentissage différents (BREIMAN, 1996). chaque sous-ensemble d'échantillons d'apprentissage, dit échantillons *bootstrap*, est obtenu par un tirage au sort de N_i échantillons avec remise parmi les N échantillons d'apprentissage (EFRON et TIBSHIRANI, 1994). La combinaison des prédictions des classifieurs appris sur les différents échantillons *bootstrap* permet d'améliorer la capacité de généralisation des algorithmes sujets au sur-apprentissage en diminuant la variance individuelle de chaque classifieur. Par ailleurs, La construction des différents classifieurs se parallélise facilement.

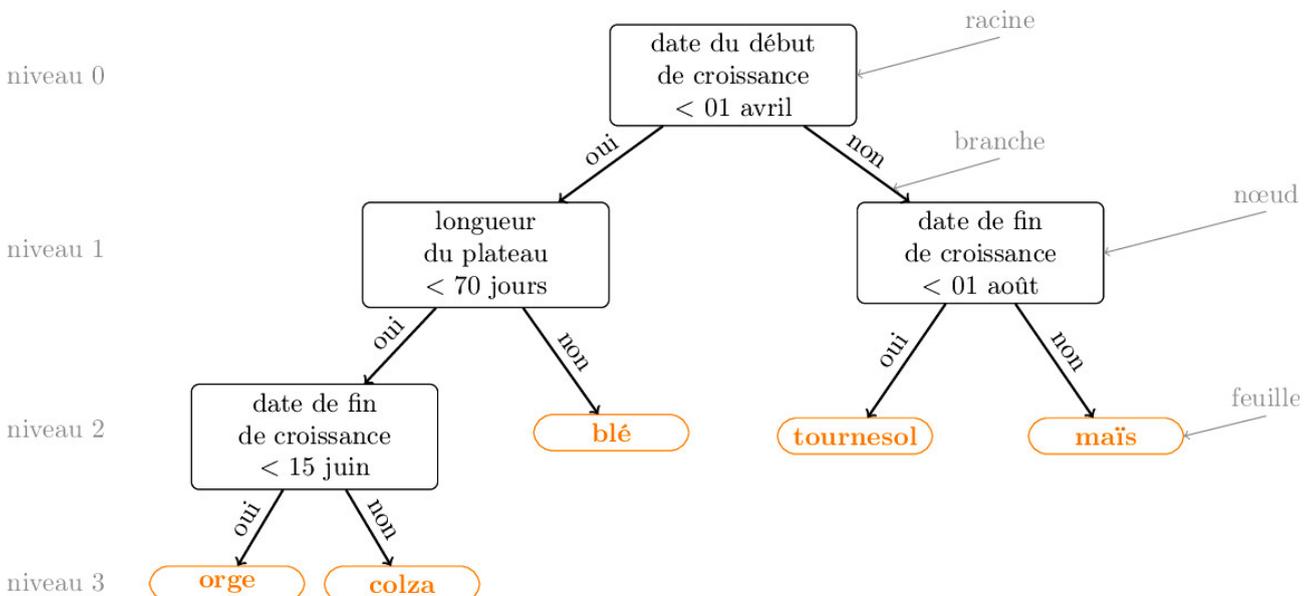
Concernant le *boosting*, il repose sur la construction de classifieurs faibles (*weak classifiers*), *i.e.* des classifieurs qui font simplement mieux que le hasard. Dans le cas d'une classification binaire, un classifieur est dit faible s'il se trompe moins d'une fois sur deux.

Dans ce cas là, l'ensemble des classifieurs est construit de manière récursive : chaque classifieur est une version adaptative du précédent où les échantillons mal prédits sont sur-pondérés. Ainsi, le classifieur de l'étape t se focalisera sur les échantillons mal prédits à l'étape $t-1$. Pour prédire l'étiquette de nouveaux échantillons, le vote de chaque classifieur est pondéré en fonction de sa précision. L'algorithme le plus connu reposant sur ce principe est *AdaBoost* (*Adaptive Boosting*) (FREUND et SCHAPIRE, 1996). Contrairement au *bagging*, l'étape d'apprentissage du *boosting* ne peut pas être parallélisée puisque les classifieurs sont dépendants les uns des autres.

2.5.2 Arbres de décision binaire

Les arbres de décision permettent de résumer un ensemble de règles dans une structure d'arbre hiérarchique. Ils ont pour avantage de fournir une représentation graphique et intuitive de la règle de décision qui permettra de déterminer l'étiquette de nouveaux échantillons.

La Figure 2.12 montre un exemple d'arbre de décision binaire pour la classification de cinq *classes de culture* en fonction de différentes informations caractérisant leur cycle phénologique. À l'état initial, l'arbre est constitué de la racine qui teste la date du début de croissance. Si cette dernière a eu lieu avant le 1er avril, alors l'échantillon emprunte la branche de gauche. Sinon, l'échantillon suit la branche de droite. Chaque noeud est ainsi défini par le choix conjoint d'une variable et d'un test qui va induire une partition en deux sous-ensembles. Les noeuds terminaux *en orange*, appelés aussi feuilles, sont des noeuds qui ne possèdent pas de noeuds fils. Ils contiennent la décision de classement final. La notion de niveau correspond à la profondeur des différents noeuds. Par convention, la racine est au niveau 0.



Source : (PELLETIER, 2017)

FIG. 2.12 – Exemple d'arbre de décision binaire pour la classification des cultures en fonction de différentes informations caractérisant leur cycle phénologique.

La construction d'un arbre de décision binaire débute avec la création de la racine qui contient l'ensemble des échantillons d'apprentissage. L'objectif est d'ajouter de nouveaux noeuds qui permettent de diviser les échantillons en sous-ensembles plus homogènes. Idéalement, un ensemble d'échantillons est homogène si les échantillons ont des comportements similaires, c'est-à-dire qu'ils appartiennent à la même classe pour un problème de classification. Comme le montre la Figure 2.12, la construction se poursuit sur plusieurs niveaux jusqu'à l'obtention de noeuds terminaux. Pour résumer, la construction d'un arbre de décision binaire nécessite :

1. La définition d'une règle de partitionnement qui permet de diviser les échantillons en sous-ensembles plus homogènes.
2. Une règle permettant de décider qu'un noeud est terminal.

3. Une règle permettant l'affectation de chaque feuille à l'une des classes. Généralement, la classe attribuée à une feuille correspond à celle la plus représentée parmi les échantillons d'apprentissage qui y appartiennent.

La règle de partitionnement est associée à chaque noeud afin de répartir les échantillons dans deux noeuds fils. Cette règle est déterminée de la manière suivante : une variable et un test associé à cette variable sont sélectionnés dans l'ensemble des variables qui décrivent les échantillons. Les échantillons sont ensuite répartis en fonction du résultat du test : si la réponse au test est positive, alors les échantillons vont dans le noeud fils de gauche, sinon ils vont dans le noeud fils de droite.

Le point crucial est le choix de la variable et du test qui lui est associé. La majorité des méthodes d'arbres de décision repose sur la même stratégie. À chaque noeud, un critère d'évaluation est effectué pour chacune des variables et pour les tests possibles sur ces variables. La variable associée à un test qui maximise le critère d'évaluation est alors choisie. Le critère d'évaluation est généralement fondé sur une mesure d'impureté, qui dépend du degré d'homogénéité des échantillons appartenant au noeud. L'impureté est minimale lorsque les échantillons appartiennent tous à la même classe, on parle alors de noeud pur. Au contraire, l'impureté est maximale si les échantillons sont répartis équiprobablement entre toutes les classes.

Formellement, le critère ΔI cherche à maximiser la différence d'impureté entre la population P du noeud et celles des populations P_g et P_d des deux noeuds fils.

$$\Delta I(P, P_g, P_d) = I(P) - (I(P_g) + I(P_d)), \quad (2.16)$$

avec I une mesure d'impureté. Comme de nombreux travaux montrent que le choix de la mesure d'impureté I n'est pas décisif (MURTHY, 1998; ROBNIK-SIKONJA, 2004), seules les deux mesures d'impureté les plus couramment utilisées sont présentées ici. Ces mesures sont calculées pour une population P composée de m échantillons d'apprentissage appartenant à K classes. Le nombre d'échantillons appartenant à la k -ième classe est noté m_k .

La première mesure est le gain d'information utilisée pour la construction des arbres *ID3* et *C4.5* (QUINLAN, 1986; QUINLAN, 1993). Elle consiste à mesurer la quantité d'information nécessaire pour déterminer la classe d'un échantillon. Elle est calculée avec l'entropie de Shannon :

$$I_H(P) = - \sum_{k=1}^K \frac{m_k}{m} \times \log_2 \left(\frac{m_k}{m} \right). \quad (2.17)$$

La seconde mesure est l'indice de Gini utilisée pour la construction des arbres (*CART*) *Classification And Regression Trees* (BREIMAN et al., 1984). Cette mesure représente l'erreur attendue si la classe d'un échantillon était choisie aléatoirement en suivant la distribution des échantillons de la population P . L'indice de Gini s'exprime alors de la manière suivante :

$$I_{Gini}(P) = 1 - \sum_{k=1}^K \left(\frac{m_k}{m} \right)^2. \quad (2.18)$$

Concernant le choix d'une règle permettant de décider qu'un noeud est terminal, la stratégie la plus simple consiste à décider qu'un noeud devienne une feuille s'il est pur, *i.e.* tous les échantillons qui le composent appartiennent à la même classe. Cependant, la construction d'un arbre jusqu'à sa profondeur maximale, *i.e.* sans l'utilisation d'un critère d'arrêt, conduit généralement à l'obtention d'un modèle trop complexe qui s'adapte parfaitement aux échantillons d'apprentissage. Afin d'améliorer la

capacité de généralisation du modèle construit et d'éviter le sur-apprentissage, il est possible d'arrêter la construction de l'arbre prématurément. Par exemple, si :

- une profondeur maximale (*max_depth*) définie par l'utilisateur est atteinte,
- le nombre d'échantillons qui composent une feuille est inférieur à un nombre minimal de paramètre (*min_samples*) défini par l'utilisateur,
- si la variance *i.e.* la pureté au sein des noeuds ne décroît pas au-delà d'un certain seuil.

Une autre solution est la méthode d'élagage (ou *pruning* en anglais). Elle consiste à construire l'arbre jusqu'à sa profondeur maximale, puis à supprimer les noeuds inintéressants.

Afin d'illustrer les différentes étapes de la construction d'un arbre de décision binaire, la Figure 2.13A montre les échantillons d'apprentissage d'un problème de classification à deux classes (*verte* et *bleue*) dans un espace à deux dimensions (variables v_1 et v_2). L'objectif est de construire un arbre de décision binaire (jusqu'à sa profondeur maximale) à partir de ces données d'apprentissage.

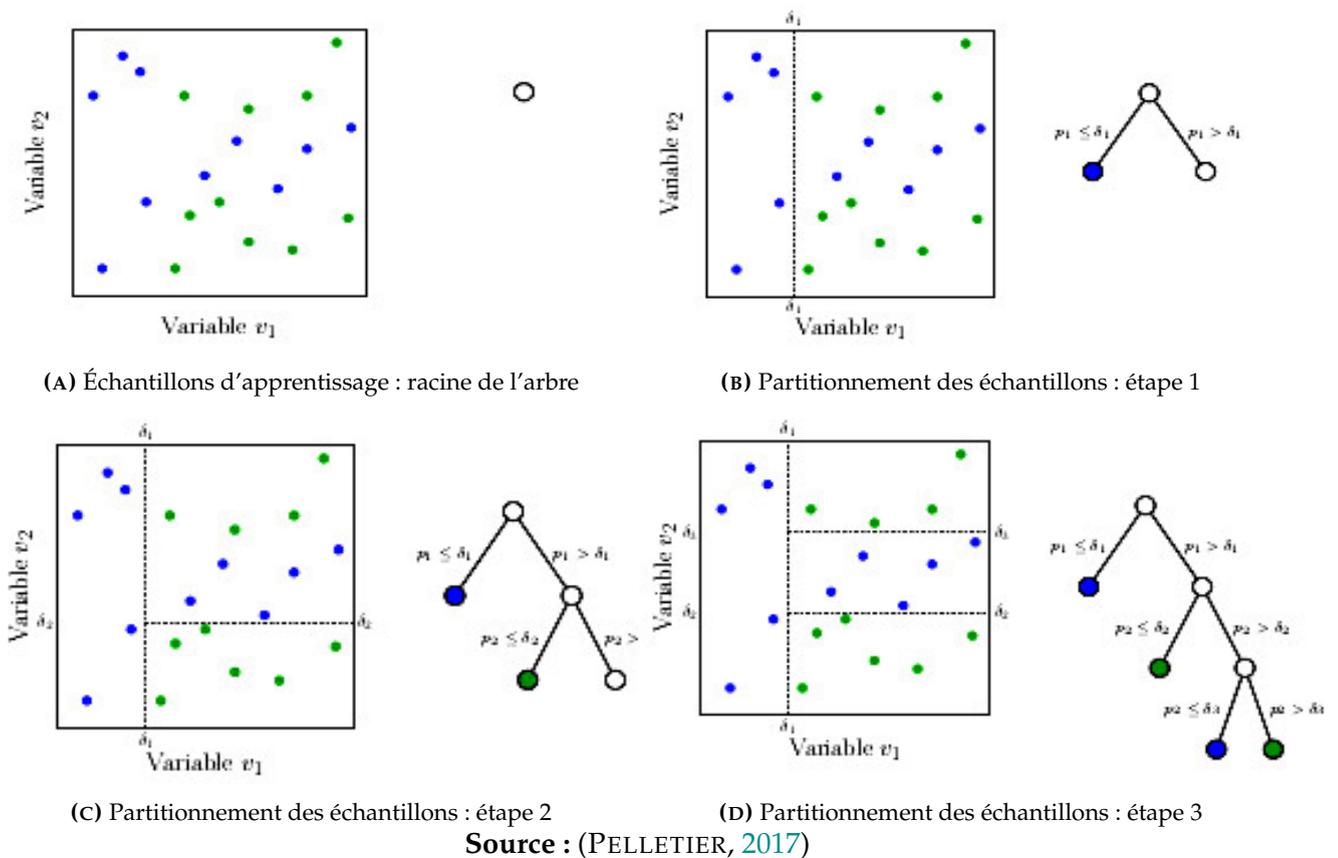


FIG. 2.13 – Principe de construction d'un arbre de décision binaire pour un problème de classification binaire à deux classes (*verte* et *bleue*).

La Figure 2.13A montre l'étape initiale où l'ensemble des échantillons appartient à la racine. Ensuite, la Figure 2.13B montre la première étape de partitionnement. La variable sélectionnée est v_1 pour une valeur de seuil δ_1 . La règle de partitionnement dépend alors du test suivant : $v_1 < \delta_1$. À la suite de cette partition, le noeud fils *de gauche* est pur, *i.e.* il contient uniquement des échantillons appartenant à la classe *bleue*. Il devient une feuille qui votera pour la classe *bleue*. Comme le montre la Figure 2.13C, la procédure de séparation des échantillons est de nouveau appliquée pour le noeud fils

de droite qui n'est pas homogène. Une étape est encore nécessaire avant que la construction de l'arbre ne s'arrête automatiquement, *i.e.* que toutes les feuilles soient des noeud purs (Figure 2.13D).

2.5.3 De l'arbre à la forêt

les arbres de décision binaire décrits précédemment sont connus pour être très sensibles au sur-apprentissage, et avoir une faible capacité de généralisation. Cependant, leur phase d'apprentissage et d'inférence rapide et la lisibilité de leur règle de décision les rendent attractifs. Ainsi, il a été proposé de construire des ensembles d'arbres de décision binaire en tirant profit des bonnes propriétés des méthodes d'ensemble, notamment l'amélioration de la capacité de généralisation.

Dans la littérature, plusieurs méthodes ont été proposées pour ajouter de la diversité à un ensemble d'arbres de décision binaire. La diversité est apportée en modifiant le processus de construction des arbres, *e.g.* en changeant les échantillons utilisés pour l'apprentissage, le critère de partitionnement des noeuds ou encore le critère d'arrêt de construction d'un arbre. Pour obtenir de bonnes performances, un ensemble d'arbres de décision binaire a besoin que chaque arbre soit performant et que les arbres du modèle soient faiblement corrélés. La corrélation entre les arbres est une mesure de diversité qui correspond au degré d'accord de prévision des arbres. Deux arbres sont faiblement corrélés si leur prévision sur un même ensemble d'échantillons sont dissimilaires. La méthode d'ensemble la plus connue utilisant un ensemble d'arbres de décision binaire est la forêt aléatoire (*Random Forest - Random Input*) proposée par (BREIMAN, 2001), qui est souvent appelée *Random Forest*. De manière classique, l'étiquette d'une nouvelle observation est obtenue par un **vote majoritaire** sur l'ensemble des résultats des arbres construits.

Le *RF* a pour spécificité :

- d'utiliser des échantillons *bootstrap* pour la construction des K arbres de décision qui constituent le modèle final ;
- d'utiliser le principe du *random feature selection* lors de la construction de chaque arbre, *i.e.* à chaque noeud, le critère de partitionnement est évalué seulement pour un sous-ensemble de m variables tirées aléatoirement sans remise avec le critère de Gini donné par l'équation (2.18) ;
- de construire les arbres jusqu'à leur profondeur maximale.

L'utilisation d'échantillons *bootstrap* et du principe du *random feature selection* permet de diversifier les arbres construits, et donc de les dé-corréler. Par ailleurs, l'utilisation d'un faible nombre de variables pour la construction de chaque noeud permet de réduire la complexité algorithmique du *RF*.

Dans l'implémentation utilisée (**Shark** (BREIMAN, 2001)) en particulier pour la production des cartes de probabilité à l'aide de la chaîne de traitement automatique *iota*², la construction des arbres est arrêtée prématurément si une profondeur maximale (*max_depth*) prédéfinie est atteinte ou si le nombre d'échantillons du noeud est inférieur à un paramètre (*min_samples*). Ceci permet d'une part de réduire le sur-apprentissage des arbres, et d'autre part de réduire la complexité algorithmique. Chaque noeud terminal vote alors pour la classe présente en majorité parmi les échantillons d'apprentissage.

De plus, le fonctionnement du *RF* permet le calcul des trois métriques particulièrement intéressantes : 1) l'erreur *OOB*, 2) l'importance des variables, et 3) le vecteur de probabilités d'appartenance aux classes pour tous les échantillons.

Pour un arbre donné, la construction avec des échantillons *bootstrap* implique qu'une partie des échantillons d'apprentissage ne soit pas utilisée pour la construction de cet arbre mais seront utilisés pour la construction d'autres arbres. Ces échantillons non-utilisés pour la construction sont appelés échantillons *OOB* (environ un tiers des échantillons sont *OOB* lorsque le nombre d'échantillons d'apprentissage est grand). Pour chaque arbre, les échantillons *OOB* permettent d'estimer l'erreur *OOB* en comptabilisant le nombre de fois où ces échantillons sont mal prédits (BREIMAN, 2001).

Le *RF* est aussi capable de donner une indication sur les variables les plus importantes. Cette information donne une connaissance des variables qui permettent d'expliquer le résultat de classification, et de celles superflues. De plus, les variables les plus importantes peuvent être utilisées afin de construire un classifieur plus performant (GENUER, POGGI et TULEAU-MALOT, 2010).

De manière intuitive, les variables les plus importantes sont celles qui sont les plus utilisées dans la construction des arbres, notamment dans les premières divisions. Cependant, cette vision est trop simpliste à cause de l'aléatoire introduit par le mécanisme de *random feature selection*. Dans la littérature, deux stratégies plus complexes sont proposées pour évaluer quantitativement l'importance des variables. La première, la plus utilisée, est le *Mean Decrease Accuracy* (GENUER, POGGI et TULEAU-MALOT, 2010). Pour une variable donnée, elle consiste à évaluer l'erreur *OOB* avant et après une permutation aléatoire des valeurs de la variable. Si une forte augmentation de l'erreur *OOB* est observée, alors la variable est importante. La deuxième mesure est le *Mean Decrease Gini* (BREIMAN et al., 1984). Elle consiste à mesurer la diminution d'impureté de chaque noeud faisant intervenir la variable considérée. Si une variable fait fortement diminuer l'impureté des noeuds, alors elle est considérée comme importante.

L'ensemble des arbres du *RF* permet aussi le calcul des probabilités d'appartenance aux classes pour chaque échantillon. Afin d'obtenir l'étiquette de nouvelles observations, chaque arbre vote pour une classe, et la classe majoritaire est attribuée. Le vote de tous les arbres permet, après division par le nombre d'arbres du modèle, d'obtenir un vecteur d'appartenance à chacune des classes.

À noter qu'un grand nombre de variantes ont été proposées dans la littérature (ROKACH, 2016), comme les *Extremely Randomized Trees*, une version totalement aléatoire sans utilisation du *bagging* où la variable et le test sont sélectionnés aléatoirement à chaque noeud (GEURTS, ERNST et WEHENKEL, 2006). Cette version ne permet donc pas d'estimer l'importance des variables, ni l'erreur *OOB* sans un jeu test indépendant. D'autres variantes modifient les règles de construction du *RF* : 1) changement de la règle de partitionnement (BREIMAN, 2001 ; ROBNIK-SIKONJA, 2004), 2) pondération des échantillons en fonction de leur utilité pour la décision finale (SASIKALA, BHARATHIDASON et VENKATESWARAN, 2015), 3) sélection ou pondération des arbres en fonction de leur précision (BERNARD, HEUTTE et ADAM, 2009 ; ROBNIK-SIKONJA, 2004 ; TSYMBAL, PECHENIZKIY et CUNNINGHAM, 2006). L'ensemble de ces variantes est décrit dans (BERNARD, HEUTTE et ADAM, 2009).

2.6 Évaluation des performances de l'algorithme de classification

L'étape d'évaluation consiste à quantifier la performance/qualité de l'algorithme de classification, et donc de la carte produite. Cette étape est effectuée en comparant les classes de la donnée de référence (vérité terrain) avec celles prédites par le classifieur sur les échantillons test.

La Figure 2.14A montre un exemple d'image synthétique pour un problème de classification à trois classes (*bleue, jaune et rouge*). La Figure 2.14B montre les échantillons test disponibles (pixels *non-blancs*)

pour cette évaluation. Afin d'effectuer cette évaluation, un tableau à double entrée appelé *matrice de confusion* ou tableau de contingence, est généralement utilisé. Chaque ligne représente le nombre d'occurrences d'une classe de la donnée de référence (réelle), tandis que chaque colonne représente le nombre d'occurrences d'une classe prédite par le système de classification. La matrice de confusion associée à l'évaluation de la carte de la Figure 2.14 est la suivante :

		Prédite		
Réelle		2	1	0
		0	3	1
		1	1	2

Les échantillons sur la diagonale représentent donc le nombre d'échantillons test correctement prédit par l'algorithme de classification, sept dans l'exemple précédent. De cette matrice de confusion, il est possible de calculer un ensemble de métriques caractérisant la qualité de la classification obtenue. les échantillons test utilisés doivent référencer la classe sur le terrain afin de ne pas biaiser les résultats (CONGALTON et GREEN, 2008). En pratique, les échantillons test sont considérés comme parfaits (FOODY, 2002) ce qui peut ne pas être le cas lorsque l'on travaille à partir de BDs existantes (comportant des erreurs ou n'étant pas à jour).

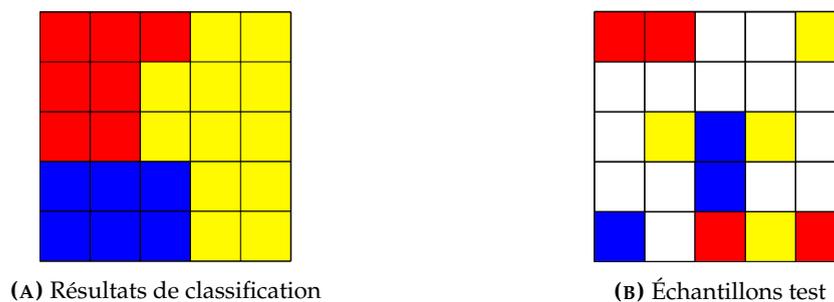


FIG. 2.14 – Exemple d'une carte d'OCS (trois classes) à évaluer à partir d'échantillons test extraits des données de référence.

Dans une première partie, les métriques d'évaluation dans le cas d'une classification multi-classes sont décrites. Une seconde partie présente un moyen d'estimer l'erreur réelle commise par le système de classification en s'appuyant sur l'intervalle de confiance.

2.6.1 Évaluation d'une classification multi-classes

Dans le cadre d'un problème de classification à K classes, la matrice de confusion C est définie ainsi :

$$\begin{bmatrix} c_{11} & \cdots & \cdots & c_{1l} & \cdots & \cdots & c_{1K} \\ \vdots & \ddots & \ddots & \vdots & \ddots & \ddots & \vdots \\ c_{i1} & \cdots & \cdots & c_{il} & \cdots & \cdots & c_{iK} \\ \vdots & \ddots & \ddots & \vdots & \ddots & \ddots & \vdots \\ c_{K1} & \cdots & \cdots & c_{Kl} & \cdots & \cdots & c_{KK} \end{bmatrix}$$

Le coefficient c_{ij} donne le nombre d'occurrences d'échantillons test appartenant à la classe i et prédit classe j par le classifieur. les échantillons test correctement prédits par l'algorithme de classification sont sur la diagonale de la matrice de confusion (coefficients c_{ii}).

La métrique la plus simple à dériver de la matrice de confusion est le taux de bonnes classifications (*Overall Accuracy (OA)* en anglais) qui est calculé comme le nombre d'échantillons test correctement prédits (trace de la matrice de confusion) divisé par le nombre total d'échantillons test :

$$OA = \frac{1}{N} \sum_{i=1}^K c_{ii}, \quad (2.19)$$

avec $N = \sum_{i=1}^K \sum_{j=1}^K (c_{ij})$, *i.e.* le nombre d'échantillons test.

En plus de la valeur d'*OA*, il est courant de calculer le coefficient *Kappa* qui doit en théorie s'affranchir du taux de bonnes classifications dues à l'aléatoire :

$$Kappa = \frac{OA - p_h}{1 - p_h}, \quad (2.20)$$

avec $p_h = \frac{1}{N^2} \sum_{i=1}^K (\sum_{j=1}^K c_{ij})(\sum_{j=1}^K c_{ji})$, le pourcentage de bonnes classifications attribué au hasard. Le référentiel de (LANDIS et KOCH, 1977) propose une interprétation du coefficient *Kappa* en fonction de sa valeur présentée dans (FOODY, 1992).

Bien que le coefficient *Kappa* soit encore très souvent utilisé, il fait polémique dans la communauté de la télédétection. La première critique concerne la formulation de p_h qui ne permettrait pas de représenter le taux de bonnes classification dues au hasard (FOODY, 1992). Une deuxième critique concerne la difficulté à réaliser des comparaisons simples entre des valeurs de coefficient *Kappa* obtenues par différents systèmes de classification (PONTIUS et MILLONES, 2011). Enfin, la dernière concerne la très forte corrélation entre la valeur du *Kappa* et de l'*OA* (LIU, FRAZIER et KUMAR, 2007). Pour ces travaux, la recommandation d'utiliser seulement l'*OA* de (STEHMAN, 1997) a été suivie¹².

Les métriques globales comme l'*OA* et le *Kappa* sont souvent insuffisantes pour mesurer la qualité de la classification, en particulier dans le cas où le nombre d'échantillons test par classe est très déséquilibré. En effet, ces mesures ne tiennent pas compte de la distribution des classes et des coûts de classification. Considérons le cas réel d'une cartographie d'arbres « pins *versus* chênes » où les pins sont bien plus présents que les chênes. Par exemple, 95 arbres sont des pins et 5 arbres sont des chênes. Si l'algorithme de classification décide que tous les arbres sont des pins, l'*OA* sera alors de 95 %. Cependant, la classe d'intérêt dans ce type de problème déséquilibré est souvent la classe minoritaire, *i.e.* les chênes. Dans ce cas, la valeur d'*OA* ne permet pas de mettre en évidence qu'aucun chêne n'est détecté par l'algorithme de classification utilisé. Afin de prendre en compte des différences de performance entre classes, des métriques par classe sont utilisées. Les mesures de précision utilisateur (*user's accuracy, UA_i*) ou *precision* en anglais, PU_i) et de précision producteur (*producer's accuracy, PA_i*) ou *recall* en anglais, PP_i) définies pour la i -ème classe sont couramment utilisées :

$$PU_i = \frac{c_{ii}}{\sum_{j=1}^K c_{ji}}, \quad (2.21)$$

$$PP_i = \frac{c_{ii}}{\sum_{j=1}^K c_{ij}}. \quad (2.22)$$

La précision utilisateur d'une classe correspond donc au pourcentage d'échantillons correctement prédits dans cette classe par rapport à l'ensemble des prédictions faites pour cette classe, tandis que la

12. Comme les valeurs du coefficient *Kappa* et de l'*OA* ont toujours indiqué des résultats cohérents dans les études réalisées, il a été décidé de ne montrer que les résultats obtenus pour l'*OA* dans ce manuscrit.

précision producteur représente le pourcentage d'échantillons de la donnée de référence correctement prédits pour cette classe. En fonction de l'application, seulement l'une des deux mesures peut être d'intérêt. Dans l'exemple précédent, s'il est important de détecter tous les chênes, une valeur de la précision producteur forte va être favorisée, quitte à détecter trop de pins comme étant des chênes (précision utilisateur faible). Au contraire, si l'objectif est d'être certain que les arbres détectés comme des chênes soient bien des chênes, la précision devra être maximisée quitte à en manquer certains (précision producteur faible).

Pour la majorité des applications, un compromis entre la précision utilisateur et la précision producteur est généralement souhaité. Il est alors possible de combiner les deux mesures en une seule nommée le $F\text{-Score}_i$ (FS_i) (ou encore $F\text{-}1_i$ et $F\text{-Mesure}_i$). Cette dernière correspond à la moyenne harmonique de la précision utilisateur et de la précision producteur. (MANNING, RAGHAVAN et AL., 2008) recommandent l'utilisation de la moyenne harmonique, plutôt qu'une moyenne arithmétique ou géométrique. Avec la moyenne harmonique, si la précision utilisateur ou la précision producteur est faible, le $F\text{-Score}$ sera aussi faible.

$$FS_i = 2 \frac{PU_i \times PP_i}{PU_i + PP_i} \quad (2.23)$$

Toutes les mesures proposées ci-dessus ne prennent pas en compte le contexte spatial induit par la classification d'images satellitaires. (COMBER et al., 2012) proposent une méthode pour évaluer spatialement les résultats de classification. Bien que très intéressante, cette approche nécessite un grand nombre d'échantillons test répartis équitablement spatialement.

2.6.2 Évaluation statistique

Toutes les métriques précédentes sont évaluées sur un ensemble d'échantillons test qui représente seulement une sous-partie de tous les échantillons. De plus, les algorithmes de classification utilisent parfois des procédures aléatoires (par exemple la technique du *bagging* pour la sélection des échantillons dans des méthodes d'ensemble). La non-exhaustivité des échantillons test et l'aléatoire présent dans les algorithmes conduisent à des incertitudes sur les mesures de performances évaluées.

Dans ces travaux, l'intervalle de confiance est calculé afin de connaître la confiance dans les mesures de performances estimées. Il sera aussi utilisé pour donner une indication sur les différences de performances entre plusieurs algorithmes de classification (FOODY, 2009; LABATUT et CHERIFI, 2012). Plus précisément, l'intervalle de confiance représente l'intervalle dans lequel la valeur réelle de la mesure de performance a $x\%$ de chance d'être comprise.

L'intervalle de confiance est ici mesuré pour $n\text{turns}$ tirages aléatoires des échantillons test. L'estimateur e d'une mesure de performance est calculé pour chaque tirage aléatoire. Ainsi, la moyenne \hat{e} et l'écart-type σ_e de cet estimateur e peuvent être calculés pour les $n\text{turns}$ tirages aléatoires. L'intervalle de confiance s'exprime alors de la manière suivante :

$$\hat{e} \pm t_{x\%} \frac{\sigma_e}{\sqrt{n\text{turns}}}, \quad (2.24)$$

avec $t_{x\%}$ le fractile. La valeur du fractile $t_{x\%}$ dépend de la valeur de x , mais aussi de $n\text{turns}$. Dans ces travaux, une loi de Student est utilisée pour déterminer la valeur de $t_{x\%}$ car le nombre de tirages aléatoires $n\text{turns}$ est petit (5 ou 10 tirages).

Chapitre 3

Zones d'étude et données

Et la géographie, c'est exact, m'a beaucoup servi. Je savais reconnaître, du premier coup d'oeil, la Chine de l'Arizona. C'est très utile, si l'on est égaré pendant la nuit.

– Antoine de Saint-Exupéry (Le Petit Prince, 1943)

Sommaire

3.1	Zones d'étude	58
3.1.1	Présentation du Cameroun	58
3.1.2	Zone d'étude Nord	65
3.1.3	Zone d'étude Ouest-Centre	68
3.2	Données géospatiales	72
3.2.1	Description des capteurs satellitaires	72
3.2.2	Description des équipements de prise de vues aériennes	74
3.2.3	Pré-traitements des données satellitaires	75
3.2.4	Génération de synthèses mensuelles d'images Sentinel-2	87
3.2.5	Génération conjointe de MNS photogrammétrique et d'ortho-images	90
3.3	Bases de données cartographiques	93
3.3.1	Bases de données cartographiques utilisées	93
3.3.2	Définition et choix d'une nomenclature	103
3.3.3	configurations de nomenclatures étudiées	104
3.3.4	Pré-traitement des données de référence utilisées	104

Résumé du chapitre :

Les cartes d'OCS sont produites à partir de méthodes d'apprentissage automatique. Comme montré au Chapitre 2, ces méthodes s'appuient sur les informations contenues dans les données géospatiales et les données de référence.

L'objectif de ce chapitre est de présenter l'ensemble des données utilisé – images géospatiales et données de référence – au cours de ces travaux de thèse. Une première partie est dédiée à la description des zones d'étude. Nous présentons tout d'abord le Cameroun en situant le pays sur le plan géographique et en décrivant les caractéristiques physiques et la diversité biologique du pays dans son ensemble et nous décrivons ensuite les deux zones d'étude dont la taille est induite par l'emprise

d'un ensemble de tuiles d'images Sentinel-2 parmi lesquelles nous nous focalisons particulièrement sur la tuile plus représentative (zone d'intérêt) au sein de chacune des zones d'étude au Cameroun. Ces deux zones se situent dans la région du Nord pour la première zone d'étude et les régions du Littoral, de l'Ouest et du Centre pour la deuxième zone d'étude et possèdent des paysages divers et variés et des OCS assez différents : majoritairement de plaines et de montagnes respectivement. Une deuxième partie présente les données géospatiales utilisées, décrit les pré-traitements appliqués aux données géospatiales et présente les générations de synthèses mensuelles de séries temporelles d'images Sentinel-2, de Modèles Numériques de Surface (MNS) et d'ortho-images dans un troisième temps. Enfin, une dernière partie présente les données de référence utilisées.

3.1 Zones d'étude

Deux zones d'étude sont étudiées. À chaque zone est associée une série temporelle d'images satellitaires acquises uniquement par un capteur optique Sentinel-2. Une série temporelle d'images acquises par un capteur radar Sentinel-1 est associée en plus à chaque zone d'intérêt (tuile représentative) au sein de chacune des deux zones d'étude. Ces deux zones sont situées dans le Nord et à l'Ouest-Centre du Cameroun. La Figure 3.1 donne des informations sur le Cameroun, découpé en tuiles Sentinel-2 (*en rouge*) à partir desquelles les deux zones d'étude sont définies. Un encart permet de visualiser en particulier la localisation du pays sur le continent africain.

3.1.1 Présentation du Cameroun

Le Cameroun est un pays d'Afrique Centrale très étendu en latitude et riverain du bassin du Congo dans sa partie Sud. Le pays atteint les rives sahéliennes du Lac Tchad dans sa partie Nord. Bordé par l'Océan Atlantique, le pays est dominé par l'un des massifs montagneux les plus hauts d'Afrique. L'ensemble constitue une très grande variété de domaines bio-géographiques, si bien qu'on a pu qualifier le pays d'une Afrique en miniature. Cette comparaison peut être poursuivie dans le domaine démographique eu égard au fait que les parties Sud et Est connaissent les plus faibles densités de l'Afrique Centrale tandis que les parties Ouest et Nord se rattachent aux hautes densités des pays du golfe de Guinée.

3.1.1.1 Situation géographique

Le Cameroun est un pays d'Afrique Centrale situé au fond du golfe de Guinée, sur la façade occidentale de l'Afrique, un peu au-dessus de l'équateur. Il possède 590 km (UICN, 1992) de côtes, très découpées, le long de l'Océan Atlantique. Très étendu en latitude de 1 200 km du Nord au Sud, le pays possède schématiquement la forme d'un triangle de 475 650 km² de superficie¹ dont la base longe 1°38 de latitude Nord (TSALÉFAC, 2006) tandis que le sommet, riverain du lac Tchad atteint les 13°05 de latitude Nord. Le pays s'étend entre 8°80 et 16°10 de longitudes Ouest.

Les coordonnées géographiques du pays indiquent clairement que le Cameroun est un pays de l'hémisphère Nord partageant ses frontières avec six autres pays du continent africain : le Nigéria à l'Ouest et au Nord-Ouest sur 1 720 km, l'Océan Atlantique au Sud-Ouest, la Guinée Équatoriale sur 183 km et le Gabon sur 298 km au Sud, le Congo au Sud-Est sur 520 km, la République Centrafricaine à l'Est sur 822 km, le Tchad à l'Est et au Nord-Est sur 1 122 km.

1. Cette superficie inclue un espace maritime. La superficie terrestre étant de 465 400 km²

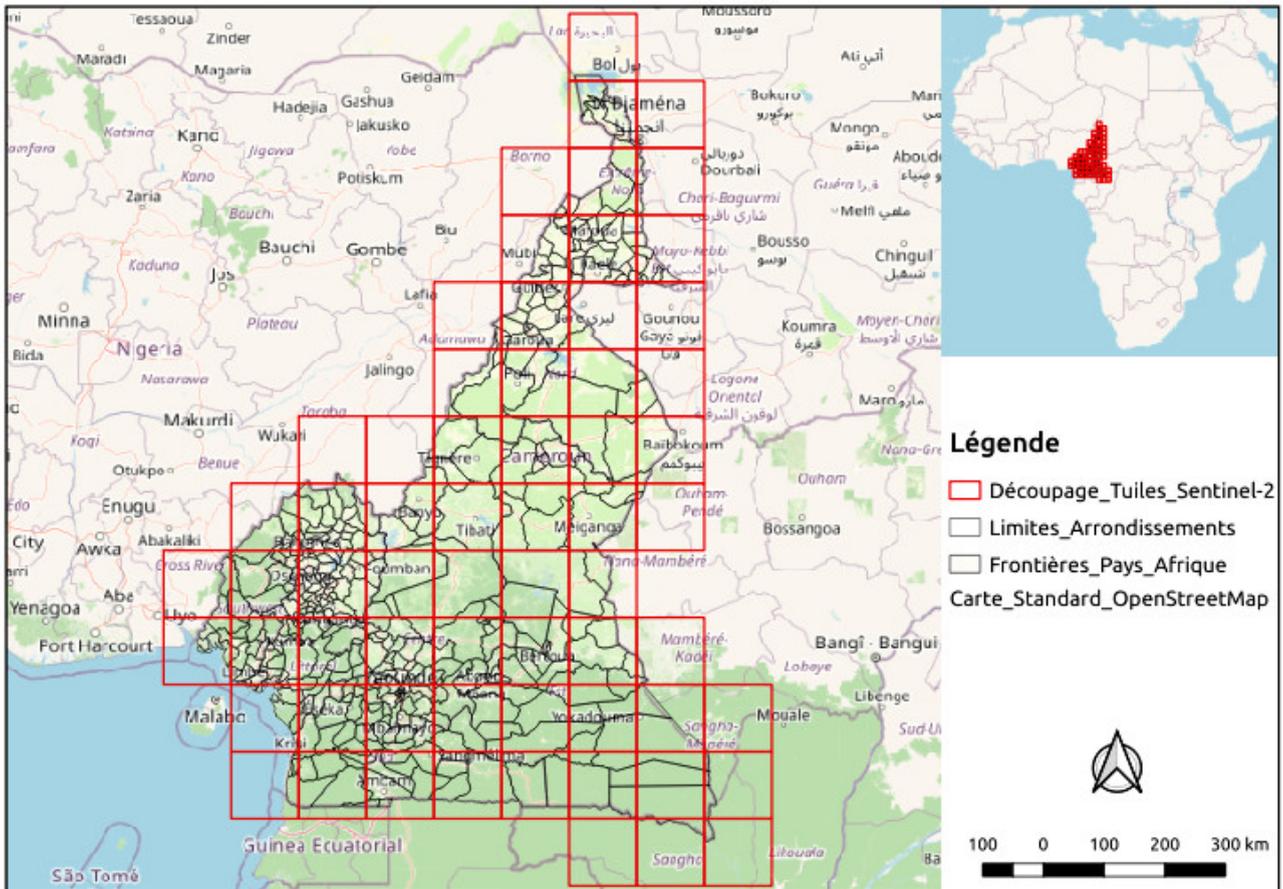


FIG. 3.1 – Carte du Cameroun avec les 360 arrondissements qui composent le pays, découpée en tuiles Sentinel-2. Un encart indique sa localisation sur le continent africain.

3.1.1.2 Caractéristiques physiques

La position géographique du Cameroun, situé au cœur de l'Afrique près de l'équateur lui donne de posséder des caractéristiques de diversité d'écosystèmes, des conditions climatiques, des paysages et des zones géomorphologiques et le pays fait partie du deuxième centre de diversité biologique du monde (Bassin du Congo).

3.1.1.2.1 Climat Le climat du Cameroun est influencé par les facteurs tels que : les masses d'air, l'éloignement de la mer, le relief et le vent. Ces facteurs permettent de distinguer deux grands domaines climatiques au Cameroun à savoir : 1) le domaine équatorial et sub-équatorial au Sud, et 2) les domaines tropicaux au Nord.

Domaine équatorial

Il est caractérisé par des précipitations abondantes avec plus de $1\,000\text{ mm}$ de précipitations chaque année et surtout par l'absence de saison sèche². L'atmosphère est humide toute l'année³. La température varie peu (entre 25 et 35°C) et l'amplitude thermique, diurne comme annuelle, est faible.

2. On parle ici de « saisons sèches » pour les périodes où il pleut moins (décembre-janvier puis juillet-août, avec des variantes locales).

3. L'humidité relative est constamment proche du point de saturation et l'insolation est réduite (moins de $2\,000\text{ h/an}$).

Ce domaine climatique comporte de nombreuses nuances, classées différemment suivant les études ; mais qui dépendent toutes du relief et de la proximité de la côte atlantique. Par exemple, la plaine côtière autour de la ville de Douala connaît un climat qualifié d'« hyper-humide » avec absence totale de saison sèche. La ville de Douala est régulièrement sous inondations en saison des pluies. De même, au pied du mont Cameroun, les précipitations connaissent des records avec plus de 7 500 mm de précipitations chaque année dans la ville de Limbé. Le relief des hautes terres de l'Ouest lui donne d'avoir un climat équatorial caractérisé par de fortes variations pluviométriques tout en y abaissant les températures. Les plateaux du Sud Cameroun et le Sud de la plaine côtière connaissent un climat de type Guinéen qui caractérise la forêt du bassin du Congo.

Domaine tropical

Le climat tropical varie en fonction de la latitude du Sud au Nord avec des modulations dues au relief et dépend de trois types très différents⁴ :

- Un climat tropical humide d'altitude autour du massif de l'Adamaoua : la pluviométrie est abondante de l'ordre de 1 500 mm par année ; mais la saison sèche s'étend des mois d'octobre à janvier dans la ville de Ngaoundéré au Nord et la température est modérée durant toute l'année variant autour de 20°C).
- Un climat tropical Soudanien autour de la cuvette de la Bénoué : les pluies demeurent abondantes de l'ordre de 1 300 mm par année dans la ville de Garoua ; mais les températures sont toujours élevées avec un rallongement de la saison sèche de 6 mois dans la même station même si les précipitations se font quand même beaucoup plus irrégulières (tornades violentes et brèves, effets des vents desséchants comme l'harmattan).
- Un climat tropical Soudano-Sahélien au Nord : les températures sont élevées ; mais avec une grande irrégularité des pluies avec par exemple la saison sèche qui s'étend sur 8 mois dans la ville de Maroua au Nord et est par conséquent supérieure à la saison des pluies.

3.1.1.2.2 Relief et montagnes Le relief peut être divisé en quatre grands ensembles organisés autour de la dorsale camerounaise qui est un ensemble de hauts sommets disposés en ligne et courant d'Est en Ouest culminant au mont Cameroun au bord de l'Océan Atlantique (TCHAWA, 2006) : 1) les basses terres du Nord, 2) la dorsale, 3) le plateau Sud-camerounais et 4) les plaines côtières.

Basses terres du Nord

Les basses terres du Nord sont globalement divisées en deux par les retombées des Monts Mandara : les plaines inondables et la plaine du Diamaré rejoignent les plaines du Tchad tandis que plus au Sud, la cuvette de la Bénoué s'encaisse entre des plateaux et des massifs granitiques ou volcaniques.

Dorsale

La dorsale s'organise du Nord au Sud de la manière suivante :

- les monts Mandara au Nord qui sont des reliefs à forte pente constitués d'« *inselbergs*⁵ » et de culots de lave culminent au Cameroun à 1 442 m.

4. La pluviométrie s'abaisse et la durée de la saison sèche augmente, de même que l'amplitude thermique diurne et annuelle.

5. Un « *inselberg* (ou *monadnock*) est un relief (colline ou un petit massif) isolé qui domine significativement une plaine ou un plateau sub-horizontale. Selon le dictionnaire de la géographie de Pierre George (1970), il s'agit brièvement d'un relief résiduel rocheux, escarpé.

- le plateau de l'Adamaoua qui est un vaste bloc de socle soulevé ponctué de petits volcans et organisé en gradins de 900 à 1 500 m d'altitude. Il domine la cuvette de la Bénoué de façon abrupte (falaise de la ville de Ngaoundéré); mais descend graduellement au Sud vers le plateau Sud-camerounais. Il est entouré à l'Ouest et au Nord de hauts reliefs tels que les Monts Mambila qui culminent à 2 460 m au Tchabal Mbabo, les Monts de Poli etc.).
- Les hauts plateaux de l'Ouest constituent un ensemble de plateaux étagés et de hauts reliefs volcaniques. Les trois plateaux principaux : le plateau Bamiléké (1 400 m-1 800 m), le plateau Bamoun (1 100 m- 1 200 m) et les « *grassfields*⁶ » (textit1 500 m-2 000 m), sont séparés par de grands escarpements. Une série de trois hauts reliefs volcaniques : le mont Oku d'altitude 3 008 m, le mont Bamboutos d'altitude 2 740 m et le mont Manengouba d'altitude 2 396 m culmine et prend fin sur la côte atlantique avec le mont Cameroun d'altitude 4 095 m.

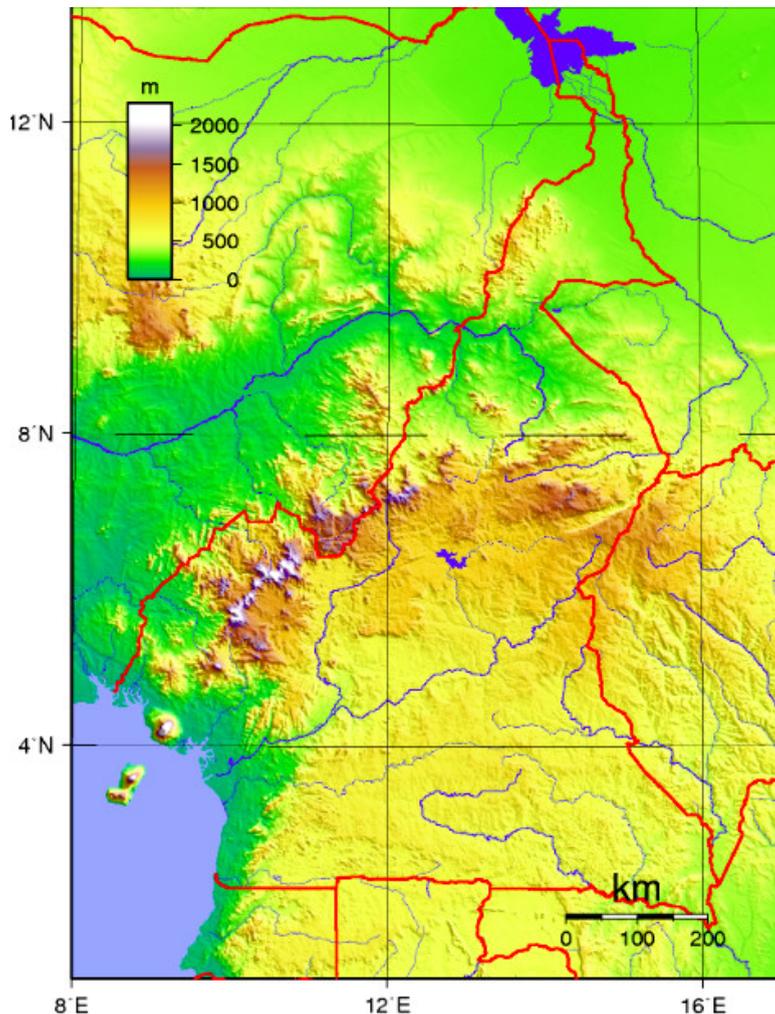


FIG. 3.2 – Altitude sur l'ensemble du Cameroun.

6. Le *grassland* est la vaste région de savane des hauts plateaux volcaniques située dans l'Ouest du Cameroun, étalé sur les régions du Nord-Ouest et de l'Ouest. Son appellation dépend des circonstances, soit *grassland* ou hauts plateaux de l'Ouest ou encore savane camerounaise.

Plateau Sud-camerounais

Le plateau Sud-camerounais d'une altitude comprise entre 650 m et 900 m, couvre environ le tiers de la superficie du pays de l'Est au Sud encadrant une étroite plaine littorale. Il constitue un relief monotone ponctué de quelques rares « *inselbergs* » autour de la capitale Yaoundé. Il s'incline faiblement en direction de la cuvette congolaise.

Plaines côtières

D'une profondeur maximale de 360 km, les plaines côtières s'étendent le long de la frontière nigériane au Nord-Ouest (cuvette de la ville de Mamfé), se rétrécissent aux abords du mont Cameroun, s'évasent dans le bassin sédimentaire de la ville de Douala et se prolongent en un mince cordon jusqu'à la frontière de la Guinée Équatoriale.

3.1.1.2.3 Végétation Le Cameroun est séparé en deux grands domaines de végétation : 1) le domaine tropical au Nord, et 2) le domaine équatorial au Sud.

Domaine tropical

La végétation qui caractérise le domaine tropical est la savane. Les variations climatiques donnent à celle-ci plusieurs aspects :

- La savane arbustive et arborée : elle couvre le plateau de l'Adamaoua. Elle est formée d'un tapis continu de graminées où surgissent par endroits des petits massifs d'arbustes et d'arbres. Cette dernière est en partie dégradé par l'action de l'Homme par des feux de brousse, des cultures et le surpâturage des troupeaux.
- La savane boisée et les forêts : elle pousse dans la cuvette de la Bénoué, principal affluent du fleuve Niger. Ce sont des tapis de graminées où la densité des arbres (baobab, acacia, palmier) est très faible. Les arbres sont séparés par des surfaces herbeuses de plus en plus étendues.

Une prairie pousse également dans la vallée du Logone, drainant une partie du grand bassin endoréique du lac Tchad et inondée pendant une partie de l'année.

Domaine équatorial

La végétation est la forêt dense. La forêt dense ombrophile recouvre l'ensemble du plateau Sud-camerounais et les basses terres côtières. La destruction de la forêt dense par le feu et les défrichements laisse place à une forêt secondaire. On y trouve aussi des galeries forestières le long des cours d'eau qui se transforment en mangrove au contact de la mer.

3.1.1.2.4 Hydrographie Le Cameroun est drainé par des cours d'eau de dimension moyenne. Le climat influence la répartition et le régime des fleuves et rivières. Les fleuves sont à l'image des traits physiques du pays. On distingue quatre bassins hydrauliques et ses fleuves : 1) le bassin de l'atlantique (le Wouri, le Nkam, le Noun et la Sanaga (plus long de 920 km et plus abondant bassin camerounais situé dans la ville d'Edéa)), 2) le bassin du Congo (le Bok, le Lobo, le Sangha et le Dja), 3) le bassin du Niger (le Mayo kébi, la Bénoué et le Faro) et 4) le bassin du Tchad (le Logone, la Vina et le Chari).

Une grande partie des cours d'eaux camerounais diverge de la dorsale camerounaise formée par le plateau de l'Ouest et de l'Adamaoua. Les fleuves qui coulent au Sud de la Sanaga, du Lom et de la Kadéï ont un régime équatorial classique c'est-à-dire qu'ils ont des hautes eaux pendant la petite et la grande saison de pluies (avril-juin et octobre-novembre). Les rivières de régime tropical ont un débit



(A) Domaine équatorial (partie Sud)

(B) Domaine tropical (partie Nord)

FIG. 3.3 – Domaines de végétation dans les deux parties Nord et Sud du Cameroun.

contrasté à l'image du climat c'est-à-dire qu'elles ont leurs hautes eaux pendant la saison de pluies (mai-septembre) et les basses eaux pendant la période sèche (octobre-avril) où le lit des cours d'eau est à sec car leurs eaux se perdent dans le sable.

On distingue également plusieurs types de lacs au Cameroun parmi lesquels : 1) les lacs de cratères *e.g.* lac Oku, lac Tizong, lac Bini et lac Barombi (dans les régions affectées par le volcanisme), 2) les lacs de subsistance *e.g.* lac Ossa, lac Dissoni et lac Ejagal (dans les basses terres surtout dans les plaines côtières), 3) les lacs de cuvette *e.g.* lac Tchad et lac Fianga s'étendant sur le territoire camerounais et sur celui des pays voisins (dans les basses terres à l'intérieur du pays), 4) les lacs artificiels *e.g.* lac Bamendjing et lac Mbakaou sur le Noun et le Djerem respectivement (faisant suite aux barrages qui ont créés d'immenses lacs de retenue), 5) etc.

Presque tous les cours d'eau sont coupés par des chutes et des rapides qui servent à de nombreux usages (navigation, irrigation, etc.).

3.1.1.3 Diversité biologique du Cameroun

Des études menées dans le domaine indiquent que la biodiversité du Cameroun est abondante et caractérisée par un degré d'endémisme, une large diversité et la fréquence de nouvelles découvertes. Le classement du mois de mars 2018 de l'Organisation Non Gouvernementale (ONG) du Fonds mondial pour la nature (*World Wide Fund for Nature (WWF)*), soulignait qu'en terme de biodiversité faunique et floristique, le Cameroun occupait la 21^{ème} place mondiale et la 4^{ème} place en Afrique après l'Afrique du Sud, le Congo et la Tanzanie. Par ailleurs, le pays contient le 2^{ème} plus grand massif forestier du bassin du Congo. Ses forêts couvrent environ 22 millions d'hectares, soit 45 % du territoire national. Notons également que près de la moitié des espèces d'oiseaux et mammifères d'Afrique vivent dans les forêts camerounaises.

3.1.1.3.1 Principaux écosystèmes Eu égard aux particularités phytogéographiques et climatiques variables d'une région à une autre, le Cameroun encore appelé l'Afrique en miniature représentant la 4^{ème} diversité biologique d'Afrique renferme 92 % des écosystèmes du continent classés selon 6 types différents : 1) l'écosystème maritime et côtier, 2) l'écosystème de la forêt tropicale dense humide, 3) l'écosystème de la savane arboré et/ou arbustive, 4) l'écosystème de la savane semi-aride, 5) l'écosystème aquatique, et 6) l'écosystème des montagnes.

3.1.1.3.2 Situation de la biodiversité L'importance de la richesse biologique du Cameroun telle que l'illustrent les données disponibles est remarquable; d'où sa 4^{ème} place en Afrique après la République Démocratique du Congo (RDC), la Tanzanie et Madagascar. La situation de sa biodiversité s'évalue à partir des sept éléments caractéristiques d'écosystème suivant : 1) La flore continentale, 2) La biodiversité maritime et côtière, 3) La biodiversité d'eau douce, 4) La faune terrestre, 5) L'agriculture, 6) Les produits de l'élevage, et 7) La biodiversité microbienne.

Flore continentale

Des connaissances actuelles, 9000 espèces végétales sur un total estimé à 12 000 ont été identifiées au Cameroun. On y dénombre 400 espèces de ligneuses dont environ une centaine d'essences commercialisées. L'inventaire n'a jusqu'ici porté que sur 14 millions d'hectares de forêt dense sur les 22 millions du secteur forestier national. Cet inventaire fait ressortir un potentiel de 4,165 milliards de m^3 de bois disponible, volume qui pourrait être multiplié par 4 s'il est pris en compte le bois de pâte à papier et le bois d'énergie. Ce potentiel de bois exploitable s'élève à 750 millions de m^3 .

Dans cette flore se retrouvent également beaucoup de produits forestiers non ligneux; mais de valeur économique réelle bien que pas encore totalement inventoriés parmi lesquels : 1) les plantes médicinales *e.g. Pygeum africanum* et *Piper guineensis*, 2) les plantes de services *e.g. Gnetum africanum* et rotin, 3) les écorces, fruits, racines, épices, fibres, 4) etc.

La mangrove qui forme la ceinture de l'écosystème maritime et côtier s'étend sur 243 km^2 et abrite 350 espèces de lianes, 15 espèces de mousses et 8 espèces de fougères.

Biodiversité maritime et côtière

Elle est impressionnante et concerne surtout la faune aquatique qui compte 542 espèces de poissons, 2 espèces de crustacées, quelques mammifères et plusieurs espèces de plancton. La flore marine bien qu'importante, n'a pas encore été inventoriée.

Biodiversité d'eau douce

Le Cameroun abrite 354 espèces de poissons dont 115 espèces endémiques sur une superficie de 3960 km^2 de cours d'eau douce.

Faune terrestre

La diversité de la faune camerounaise est impressionnante et renferme : 1) 409 espèces de mammifères (11 espèces endémiques et 27 espèces menacées), 2) 1000 espèces d'oiseaux (25 espèces endémiques, 47 espèces menacées et 1 espèce éteinte), 3) 183 espèces de reptiles (19 espèces endémiques et 2 espèces menacées), 4) 85 espèces de serpents, 5) 190 espèces de batraciens (1 espèce menacée), 6) 1110 espèces d'insectes et 7) 1050 espèces de papillons.

Agriculture

La diversité des produits agricoles camerounais concerne : 1) les céréales *e.g.* maïs, sorgho, millet et riz, 2) les tubercules *e.g.* manioc, patate, ignames et pomme de terre, 3) les légumes *e.g.* arachides, haricot et pois, 4) les bananes *e.g.* banane et banane plantain, 5) les fruitiers *e.g.* agrumes, mangues et ananas, 6) les cultures de rente *e.g.* cacao, café, thé, coton, hévéa et palmier à huile, 7) etc.

Produits de l'élevage

L'élevage est concentré sur le boeuf, le mouton, la chèvre, le porc et le poulet.

Biodiversité microbienne

Plus de 300 espèces de champignons et de bactéries sont actuellement répertoriées et leur rôle reconnu d'importance en agriculture, foresterie, santé et industrie.

3.1.2 Zone d'étude Nord

Au cours de ces travaux, les deux zones d'étude au Cameroun sont choisies pour la situation de leur biodiversité représentative du territoire national tout entier.

Ces deux zones d'étude - ZONE1 et ZONE2 - au Cameroun sont représentées *en bleu* sur les Figures 3.4 et 3.7 respectivement. La taille de ces zones d'étude est induite par l'emprise des blocs de tuiles T33PTM-T33PUM-T33PUL-T33PTL-T33PTK-T33PUK et T32NMM-T32NNM-T32NPM-T32NQM-T32NQL-T32NPL-T32NNL-T32NML-T32NMK-T32NNK-T32NPK-T32NQK d'images Sentinel-2 sur la première zone d'étude (ZONE1) au Nord et la deuxième zone d'étude (ZONE2) à l'Ouest-Centre respectivement. Les deux zones d'intérêt - T33PUL (au sein de la ZONE1) et T32NPL (au sein de la ZONE2) - sont représentées sur les Figures 3.5 et 3.8. La taille de ces zones d'intérêt est induite par l'emprise des tuiles T33PUL et T32NPL d'images Sentinel-2.

3.1.2.1 Localisation géographique

La zone d'étude Nord (ZONE1) est couverte par le bloc constitué des six tuiles - T33PTM, T33PUM, T33PUL, T33PTL, T33PTK et T33PUK - d'images Sentinel-2. Cette zone est entièrement située dans au Nord du Cameroun. Elle est localisée dans le domaine tropical de végétation. Elle a une superficie d'environ 72 600 km² y compris les zones de recouvrement entre les tuiles et se situe entre 7°57' et 10°59' de latitude Nord et entre 12°01' et 14° de longitude Est (Figure 3.4).

Concernant la première zone d'intérêt (T33PUL), elle se trouve au sein de la zone d'étude ZONE1 et possède une superficie de 12 100 km² induite par l'emprise de la tuile T33PUL. Cette zone se situe précisément entre 9° et 10° de latitude Nord et entre 13° et 14° de longitude Est (Figure 3.5).

3.1.2.2 Caractéristiques physiques

3.1.2.2.1 Climat La ZONE1 appartient à la zone soudanienne et jouit d'un climat tropical à saison sèche marquée. Ce climat est caractérisé par deux saisons : une saison pluvieuse de 6 mois s'étendant de février à septembre et une saison sèche de 6 mois qui va d'octobre à janvier marquée par des tornades violentes et brèves, des effets de vents desséchants comme l'harmattan (vent sec et chaud). L'écosystème dans cette zone a été façonné par les éléments climatiques suivants :

- Les températures : la température moyenne mensuelle varie entre 28°C et 35°C. Les extrêmes thermiques sont en moyenne d'un minimum de 22°C en décembre et d'un maximum de 40°C en mars. L'amplitude thermique quotidienne est faible (entre 6 à 7°C). Les mois de janvier et février sont les mois les plus chauds au cours desquels on enregistre souvent les températures maximales de l'année (> 30°C). Le mois de juin constitue le mois le plus froid avec des nuits très fraîches (dans le contexte camerounais) au cours desquelles les températures se situent souvent autour de 20°C comme montré dans la Figure 3.6.
- les précipitations : la pluviométrie moyenne varie entre 900 et 1500 mm sur la ville de Garoua. Les maximums de pluie sont enregistrés au cours des mois de juillet à septembre avec le pic atteint au mois d'août avec une précipitation moyenne 233 mm. Les mois de décembre, janvier et

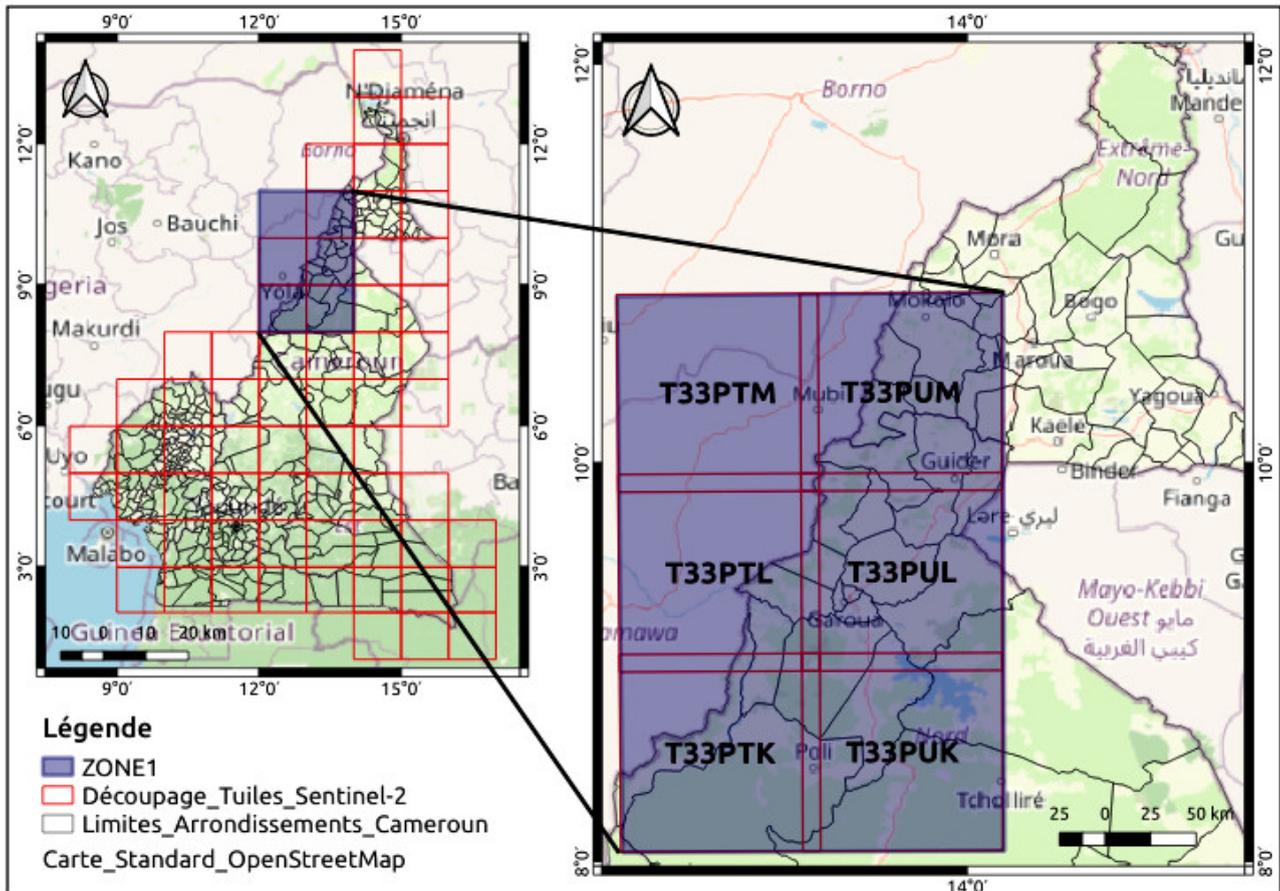


FIG. 3.4 – Localisation de la première zone d'étude (ZONE1).

février sont les mois les plus secs avec $0,2 \text{ mm}$, $0,0 \text{ mm}$ et $0,1 \text{ mm}$ de pluie au cours desquels on note surtout l'effet desséchant de l'harmattan (vent très sec) comme montré dans la Figure 3.6.

3.1.2.2.2 Relief Le relief de la ZONE1 est du même type que celui de la région des savanes du Cameroun. Ce relief est très peu accidenté avec des pentes très faibles et est composé de deux ensembles : 1) les plaines inondables et 2) la plaine du Diamaré. La partie septentrionale de la plaine du Diamaré rejoint les plaines du Tchad tandis que plus au Sud, la cuvette de la Bénoué s'encaisse entre les plateaux et des massifs granitiques ou volcaniques. Toute la zone étant une pénéplaine, il existe très peu ou presque pas de zone à pente forte, facilitant l'utilisation des données radar.

3.1.2.2.3 Sol Les sols de la ZONE1 présentent différentes variantes. On distingue les types suivants :

- Les sols ferrugineux tropicaux : de teinte rougeâtre à brun-rougeâtre, sableux, de profondeur variable en fonction de la distance aux reliefs résiduels ou des sommets des dômes. Ces sommets des dômes voient fréquemment apparaître des affleurements gréseux, souvent ferrugineux (carapacés) en place. Ces sommets à sols peu épais forment les « noyaux durs » des ondulations où l'érosion a déjà tout déblayé jusqu'à la roche alors que les glacis versants sont tapissés par les colluvions corrélatives de cette érosion.
- Les sols ferrugineux tropicaux hydromorphes : la couleur est gris-brunâtre à gris-jaunâtre, parfois tachetée de rouille à partir de 60 cm . Le taux de matière organique ($0 - 20 \text{ cm}$) est de l'ordre de

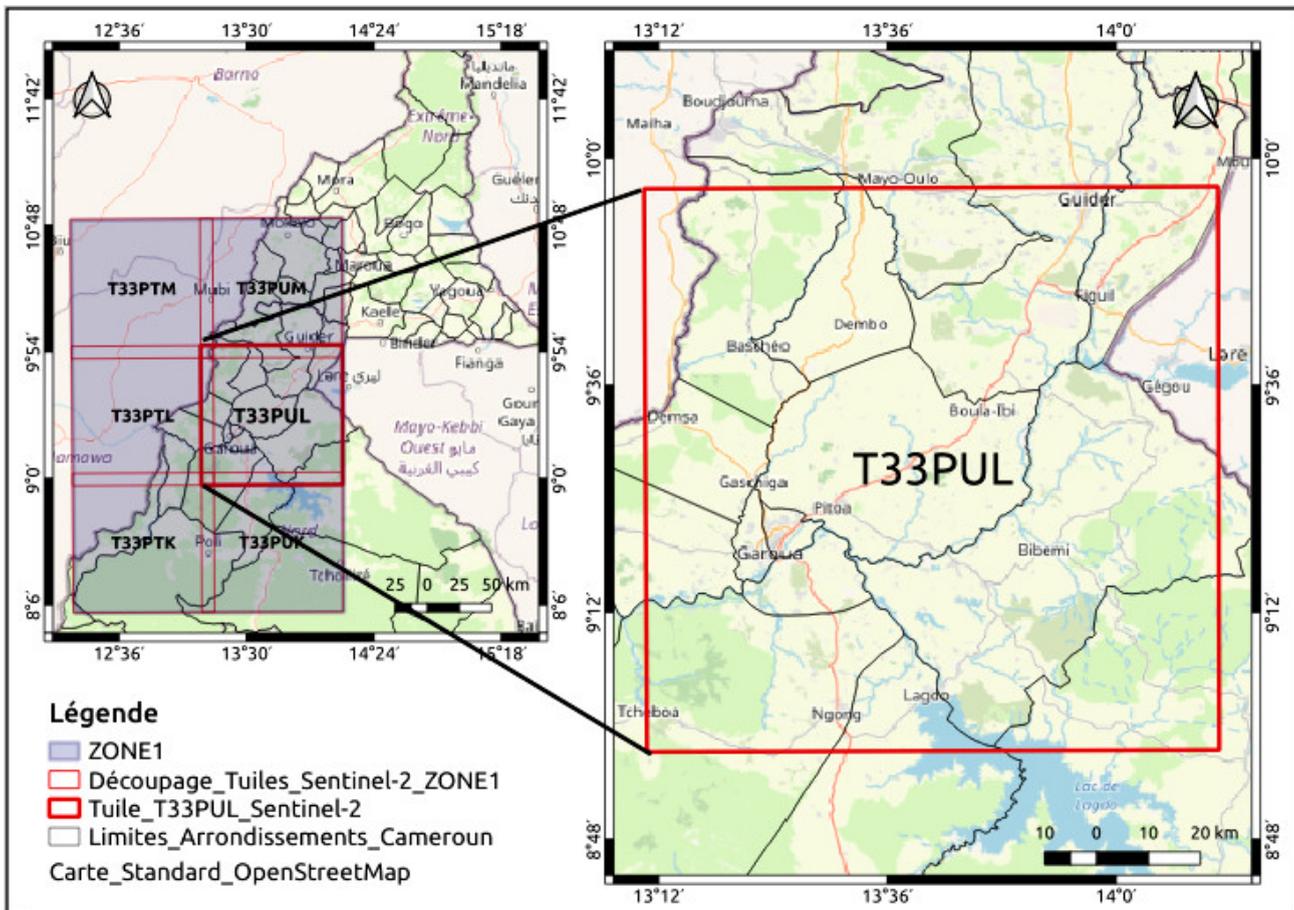
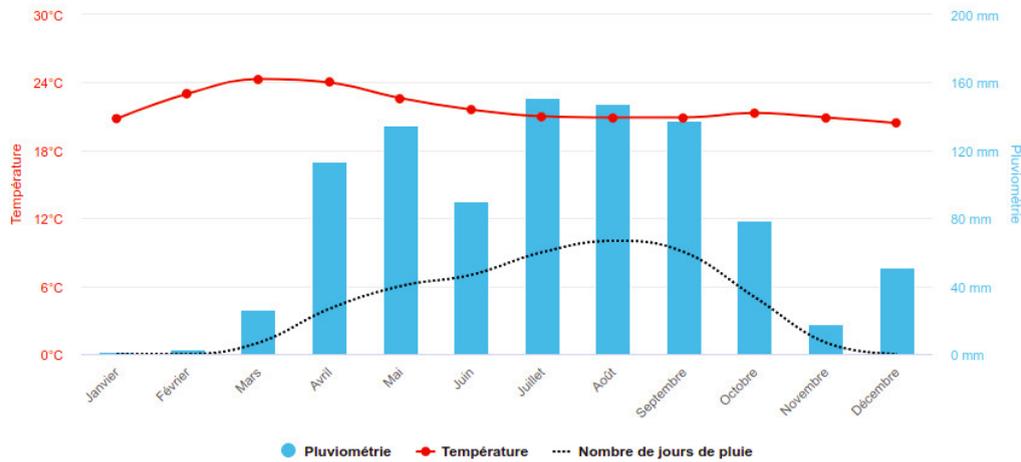


FIG. 3.5 – Localisation de la première zone d'intérêt *T33PUL*.

1 à 2 %. A l'état naturel, ces sols sont soumis à une activité biologique importante (nombreux turricules gris de vers de terre en surface, termitières petites et grandes). Cette activité est sans doute en relation avec la présence temporaire d'une nappe phréatique perchée. La texture est limono-sableuse à limono-argilo-sableuse en surface (12 à 25 % d'argile); elle est argilo-sableuse (35 à 45 % d'argile) à partir de 60 cm de profondeur. Il y a donc appauvrissement en argile en surface avec colmatage du sous-sol. La structure est à tendance massive à polyédrique en surface, polyédrique en profondeur. Le potentiel d'Hydrogène (pH) se situe aux alentours de 6. La capacité d'échange, de l'ordre de 10 % en surface atteint 20 % en dessous. Le taux de saturation est de l'ordre de 50 %. La teinte générale plutôt terne de ces sols ainsi que les taches rouilles nombreuses font penser à la présence d'engorgements temporaires en hivernage.

3.1.2.2.4 Réseau hydrographique La ZONE1 est très bien drainée. Son réseau hydrographique se répartit entre deux bassins. Le bassin Atlantique est constitué par la Bénoué et ses affluents dont le principal est le Faro. Le débit de la Bénoué varie énormément au cours de l'année passant de $1\,870\text{ m}^3/\text{s}$ en septembre à $2,45\text{ m}^3/\text{s}$ en avril à la station de Garoua. La Bénoué connaît également un intense alluvionnement à partir de son cours moyen. Ensuite, le bassin du lac Tchad est constitué des torrents issus des monts Mandara et du système Logone/Chari. Les cours d'eau issus des montagnes sont caractérisés par un écoulement torrentiel dans leur cours supérieur et fluvial dès leur débouché dans la plaine de piémont. Le système Logone/Chari se différencie par un écoulement permanent,



Source : <https://planificateur.a-contresens.net/afrique/cameroun/nord/garoua/2231320.html>

FIG. 3.6 – Courbes ombro-thermiques de la ville de Garoua dans la ZONE1.

une faible pente (1/7 000), de vastes zones d'inondation et un alluvionnement intense.

La ZONE1 renferme des écosystèmes humides riches en espèces aquatiques qui lui confèrent aussi une reconnaissance internationale.

3.1.2.3 Diversité biologique de la zone d'étude Nord

La diversité biologique de cette zone est façonnée par l'effet du climat, du type de sol et des formations végétales dans la région du Nord. Plusieurs analyses de la dynamique d'installation des espèces dans cette zone ont permis de discerner 3 grands groupes d'espèces :

- Groupe I : il est constitué d'espèces dont certaines, abondantes au moment de la culture, régressent progressivement à la suite de l'abandon, pour disparaître finalement : *Leucas martinicensis*, *Acaclypha ciliata*, *Commelina bengalensis*, *Launaea chevalieri*, etc.
- Groupe II : il est constitué d'espèces qui se mettent en place dès le début de l'abandon des cultures. Elles atteignent l'optimum de leur développement dans les stades jeunes, et régressent plus tard dans la succession sans disparaître complètement : *Piliostigma reticulatum*, *Cassia singueana*, *Annona senegalensi*.
- Groupe III : il est constitué d'espèces absentes ou rares au début de l'abandon ; mais dont le développement augmente ensuite et régulièrement. Il est plus riche en phanérophytes qui sont les ligieux des savanes : *Acacia ataxacantha*, *Balanites aegyptiaca*, etc.

3.1.3 Zone d'étude Ouest-Centre

3.1.3.1 Localisation géographique

La zone d'étude Ouest-Centre (ZONE2) est couverte par le bloc constitué des douze tuiles - T32NMM, T32NNM, T32NPM, T32NQM, T32NQL, T32NPL, T32NNL, T32NML, T32NMK, T32NNK, T32NPK et T32NQK - d'images Sentinel-2. Cette zone est partiellement située à l'Ouest et au Centre du Cameroun. Elle est localisée dans le domaine équatorial de végétation. Elle a une superficie d'environ 145 200 km² y compris les zones de recouvrement entre les tuiles et se situe entre 3°59' et 7° de latitude Nord et entre 8° et 12° de longitude Est comme présentée dans la Figure 3.7.

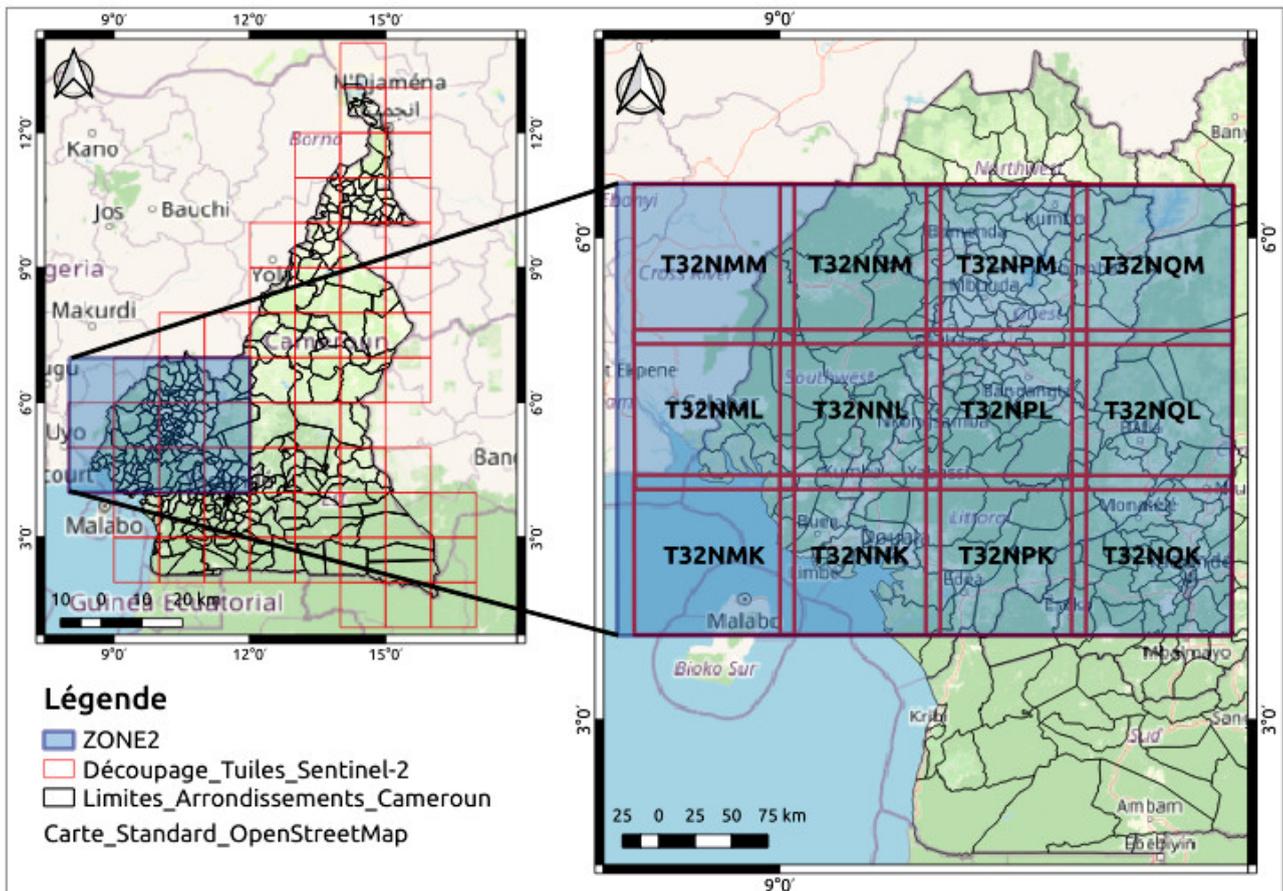


FIG. 3.7 – Localisation de la deuxième zone d'étude (ZONE2).

La Figure 3.8 présente la deuxième zone d'intérêt (*T32NPL*). Elle se trouve au sein de la zone d'étude ZONE2 et possède une superficie de $12\ 100\ km^2$ induite par l'emprise de la tuile *T32NPL*. Cette zone se situe précisément entre 5° et 6° de latitude Nord et entre 10° et 11° de longitude Est.

3.1.3.2 Caractéristiques physiques

3.1.3.2.1 Climat La ZONE2 fait partie du domaine équatorial caractérisée par un climat de type équatorial de transition résultant du mouvement de deux types de masses d'air de hautes pressions. Il s'agit des masses d'air continentales venant du Nord-Est et caractérisées par l'harmattan (vent sec et chaud) et des masses d'air maritimes venant du Sud-Ouest et caractérisées par la mousson (vent humide et chaud). La zone de rencontre de ces deux masses d'air détermine le Front Inter Tropical dont la fluctuation au cours de l'année est à l'origine des saisons. Ce type de climat se caractérise par une alternance de deux saisons des pluies et de deux saisons sèches bien marquées : une grande saison des pluies de juin à octobre, une petite saison sèche de octobre à décembre, une petite saison des pluies de décembre à janvier et une grande saison sèche de février à mai.

La pluviométrie annuelle varie entre 1000 et $1300\ mm$. Ces précipitations sont plus fortes pendant les saisons des pluies. Le maximum de précipitations est atteint au mois d'août avec des précipitations de plus de $161\ mm$. La température moyenne annuelle est atteinte au mois de mai ($30,45^{\circ}C$).

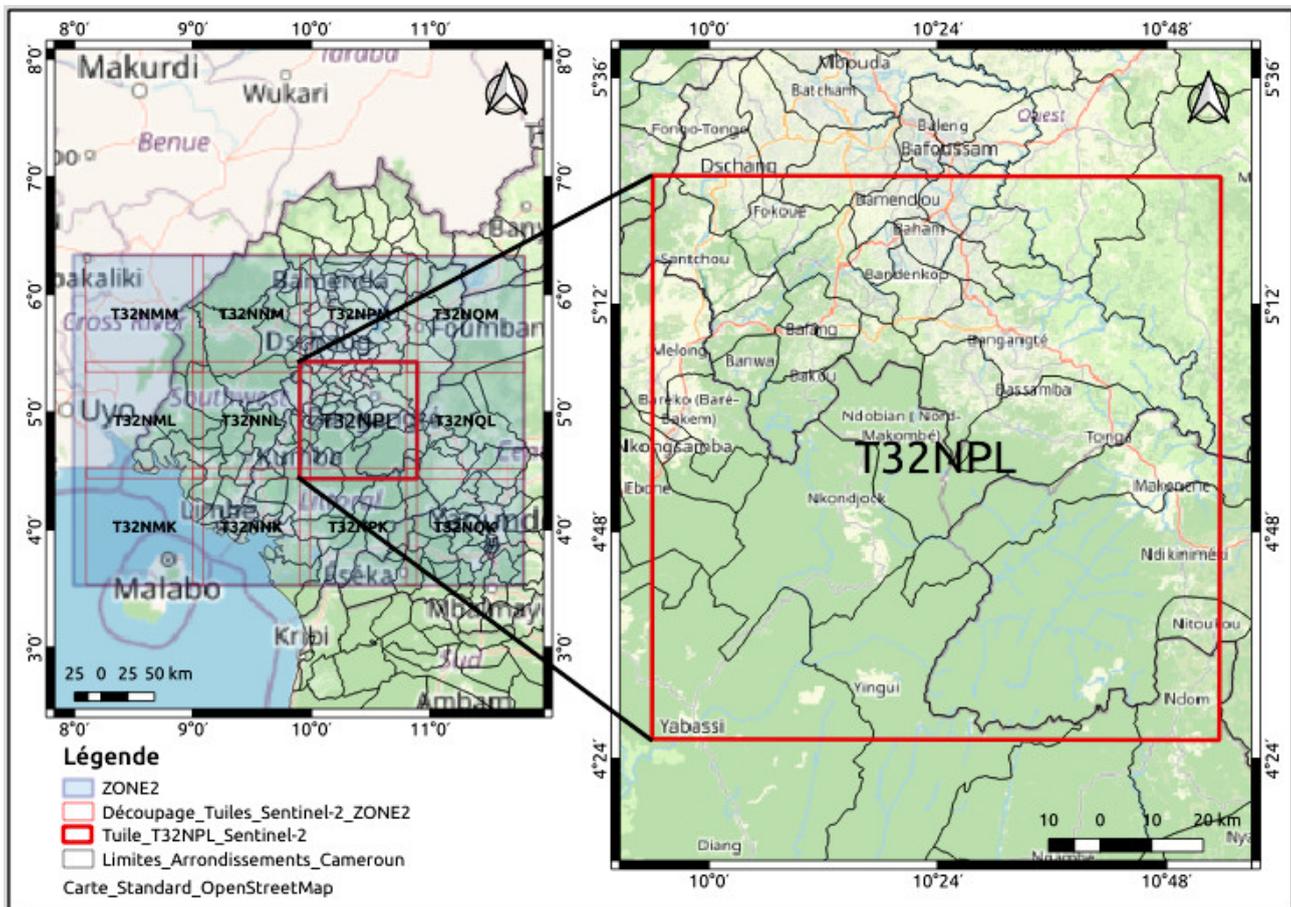


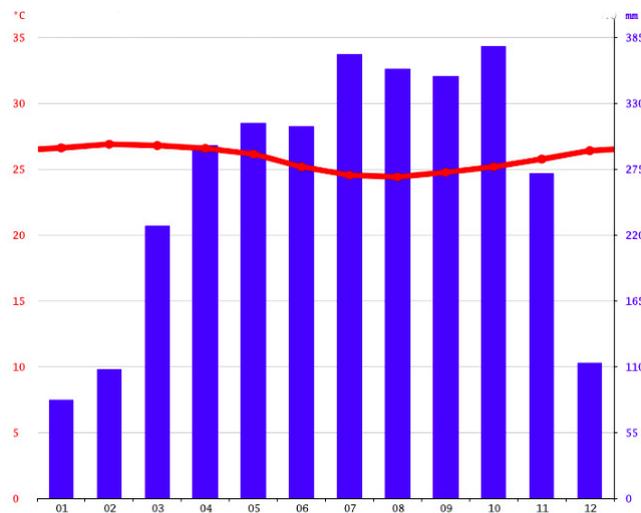
FIG. 3.8 – Localisation de la deuxième zone d'intérêt T32NPL.

La courbe ombrothermique présentée dans la Figure 3.9 indique que la zone jouit d'une double saison des pluies, caractéristique de la région côtière. Cette particularité est importante à mentionner car elle permet aux agriculteurs de réaliser deux cultures par an sur la même parcelle.

3.1.3.2.2 Relief Le relief de la ZONE2 est du même type que celui de la région des forêts du Cameroun. Ce relief est assez accidenté avec des fortes pentes par endroit et est composé de trois ensembles : 1) le plateau Bamiléké, 2) le plateau Bamoun et 3) les « grassfields ». Ces trois ensembles sont séparés par de grands escarpements. L'ensemble de la zone ne constituant pas une pénéplaine car il y subsiste des zones à pente forte qui rendent difficiles l'utilisation des données radar.

3.1.3.2.3 Sol Les sols qui se développent sur les formations géologiques dans la ZONE2 sont assez divers. Ils appartiennent à deux classes de sols :

- Les sols ferrallitiques humifères : on les retrouve au sommet de montagnes basaltiques de l'Ouest à plus de 2 000 m sous des pluviométries élevées. L'horizon humifère est très important et atteint 40 à 60 cm.
- Les sols ferrallitiques fortement désaturés (ou sols jaunes) : ces sols couvrent de larges superficies dans le Sud-Ouest du pays où la pluviométrie est supérieure à 2 mètres et répartie sur un grand nombre de mois (généralement 10 mois). Ils dérivent de roches sédimentaires ou métamorphiques. La végétation naturelle est la forêt dense ombrophile.



Source : climate-data.org

FIG. 3.9 – Courbes ombro-thermiques de la ville de Douala dans la ZONE2.

3.1.3.2.4 Réseau hydrographique La ZONE2 regroupant les trois régions du Littoral, de l'Ouest et du Centre est principalement drainée au niveau de la région du Littoral par quatre cours d'eau :

- Le Wouri : principal cours d'eau du Sud-Ouest qui draine toute la partie Sud des villages Bamiléké. Il est formé par la réunion du Nkam et du Makombé.
- Le Nkam : il descend des monts Bamboutos d'altitude 2 600 m par son affluent la Menoux. Sa pente est très rapide dans son cours supérieur où il franchit les chutes, bien connues, d'Ékom au Sud de la route du village Bafang, près de la ville de Nkongsamba. La pente s'accroît entre les cotes 500 et 200, et diminue avant le confluent de la Makombé.
- La Makombé : elle est constituée par un éventail de petits cours d'eau à très forte pente prenant leur source dans le massif de Bana du village Bafang entre les cotes 2000 et 800 m. La rivière principale a un cours beaucoup moins rapide.
- La Dibamba : elle est formée par la réunion de l'Ebo, de l'Ékem et de la Dibamba proprement dite. De nombreuses chutes coupent le cours de ces petites rivières. elle se termine au Sud de la ville de Douala. Son bassin possède alors une superficie de de 2 700 km²,

Et quatre rivières principales au niveau de la région de l'Ouest :

- La Mape au Nord : affluent du Mbam.
- Le Nkam au Sud-Ouest : fleuve côtier se jetant dans la mer à Douala sous le nom du Wouri. Il draine la bordure Sud-Ouest du plateau Bamiléké et la ville du Dschang.
- Le Ndé au Sud-Est : affluent du Noun.
- Le Noun : il draine l'essentiel de la province de l'Ouest après avoir pris naissance dans le massif de l'Oku (3 070 m) puis divague dans la plaine de Ndop aujourd'hui inondée par l'ouvrage de retenue de Bamendjin. Il reçoit en rive droite deux affluents d'égale importance drainant le plateau Bamiléké et en rive gauche, de petits affluents issus du village Bamoun.

3.1.3.3 Diversité biologique de la zone d'étude Ouest-Centre

Cette zone d'étude est caractérisée par de fortes variations d'altitude avec la présence des hauts plateaux de l'Ouest et des plaines du Littoral en raison du fait qu'elle regroupe particulièrement ces deux régions du Cameroun. Cette zone contient également une flore assez riche et variée. Au niveau du Littoral, elle présente des formations végétales très dégradées. On y retrouve entre autre le Lion (*Panthera leo*), l'éléphant (*Loxodonta*), Buffle (*Syncerus caffer nanus*), Girafe (*Giraffa camelopardalis*), Guépard (*Acinonyx jubatus*), Hippotrague (*Hippotragus equinus*), Bubale (*Alcephalus busephalus*), Bushbuck (*Tragelaphus scriptus*), Céphalophe de Grimm (*Cephalophus grimmia*), Damalisque (*Damaliscus lunatus*), Cob de buffon (*Kobus kob kob*), Lycaon (*Lycaon pictus*), Rhinocéros noir (*Diceros bicornis*), Wart Hog (*Phacochoerus aethiopicus*), Eland de Derby (*Taurotragus oryx*), Singe vert (*Cercopithecus aethiops*), Babouin (*Papio cynocephalus*), Hippopotame (*Hippopotamus amphibius*, *Hippopotamus amphibius schadenensis*), Python sebae (*Python sebae*), Tortue (*Cyclanorbis senegalensis*), Autruche (*Struthio camelus*), etc. La plupart de ces espèces ont une vaste distribution et sont assez tolérantes vis-à-vis de changements de leur habitat. Ces animaux sont pour la plupart conservés à l'intérieur des aires protégées.

3.2 Données géospatiales

3.2.1 Description des capteurs satellitaires

Dans le cadre des travaux de cette thèse, nous avons mené des expériences de recherche en se servant des données optiques en accès libre provenant du capteur Sentinel-2 d'une part, et des données radar Sentinel-1 et des données optiques d'images aériennes à accès limité provenant d'un capteur d'images aériennes d'autre part.

3.2.1.1 Description du capteur optique Sentinel-2 (S-2)

Le programme européen *Copernicus* développé par l'ESA a pour objectif de surveiller la planète Terre en dotant le continent Européen d'une capacité opérationnelle et autonome d'observation de la Terre en tant qu'un service d'intérêt général européen, à accès libre, plein et entier. Il s'agit de mettre à disposition et en accès libre des produits cartographiques et des données satellitaires de qualité dans le domaine du suivi des composantes de l'environnement. L'ESA a ainsi développé un ensemble de missions appelées mission Sentinel destinées entre autres à la mise en orbite d'un ensemble de satellites optiques et radar afin de répondre aux objectifs opérationnels du programme *Copernicus*.

Depuis 2014, le programme a permis la mise en orbite des satellites optiques multi-spectraux Sentinel-2A en décembre 2015 et Sentinel-2B en décembre 2016. Les deux satellites Sentinel-2A/-2B sont sur une même orbite héliosynchrone, déphasés de 180° l'un par rapport à l'autre. Ces capteurs sont caractérisés par une résolution spatiale variable en fonction des bandes spectrales. Les images Sentinel-2 comprennent au total 13 bandes allant du domaine du visible au moyen infrarouge. Les tailles des pixels varient entre 10 m, 20 m et 60 m. Le temps de revisite à l'équateur est de 10 jours pour chaque satellite. Il est donc de 5 jours pour le couple Sentinel-2A/-2B.

La charge utile du couple Sentinel-2A/-2B est composée de l'instrument « *Multi-Spectral Instrument (MSI)* » (caractéristiques dans le Tableau 3.1). L'imagerieur MSI a une fauchée de 290 kilomètres et une masse totale de 1200 kilogrammes tout en étant disposé à une altitude de 786 kilomètres.

Ces images sont utilisées dans de multiples applications comme le suivi du développement de l'OCS, des cultures et forêts, des pratiques et productions agricoles etc. Sa période de revisite de 5

jours à l'équateur et la haute résolution spatiale de 10 m font de ces données un outil exceptionnel pour l'étude de l'évolution de l'OCS et de l'impact du réchauffement climatique.

TAB. 3.1 – Caractéristiques de l'instrument *Multi-Spectral Instrument (MSI)* embarqué sur les deux satellites Sentinel-2 (<https://www.sentinel2.cnes.fr>).

	Canal	Résolution spatiale (m)	Bande spectrale (μm)
Multispectral (XS)	<i>Aérosol</i>	60	0,43 - 0,45
	<i>Bleu</i>	10	0,46 - 0,52
	<i>Vert</i>	10	0,54 - 0,58
	<i>Rouge</i>	10	0,65 - 0,68
	<i>Red-edge 1</i>	20	0,70 - 0,71
	<i>Red-edge 2</i>	20	0,73 - 0,74
	<i>Red-edge 3</i>	20	0,77 - 0,79
	<i>Proche infra-rouge 1</i>	10	0,78 - 0,90
	<i>Proche infra-rouge 2</i>	20	0,85 - 0,87
	<i>Vapeur d'eau</i>	60	0,93 - 0,95
	<i>Moyen infra-rouge 1</i>	20	1,57 - 1,66
	<i>Moyen infra-rouge 2</i>	20	2,10 - 2,28
	<i>Cirrus</i>	60	1,37 - 1,39

3.2.1.2 Description du capteur radar Sentinel-1 (S-1)

Au cours des travaux, nous avons exploité des données radar que nous avons à notre disposition en accès libre et provenant essentiellement du capteur Sentinel-1.

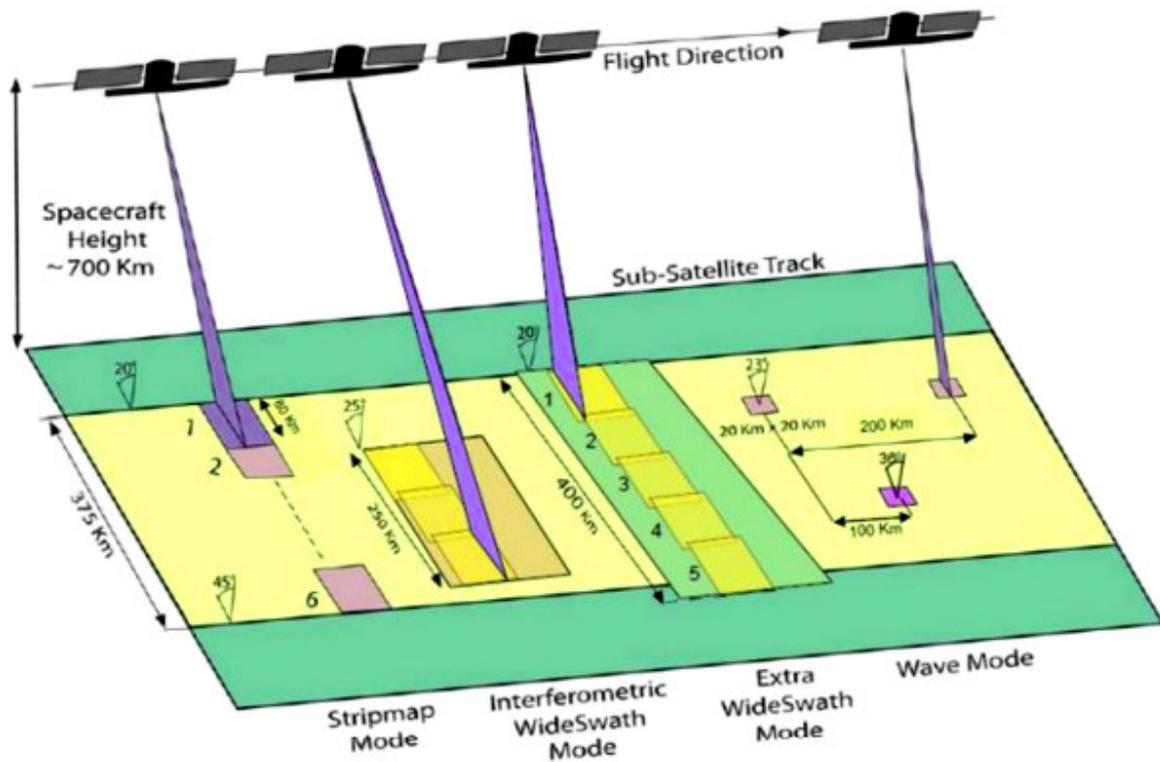
Le système Sentinel-1 est composé de satellites radar d'observation de la Terre de l'ESA développés dans le cadre du précédent programme *Copernicus*. La mission Sentinel-1 est également basée sur une constellation de deux satellites Sentinel-1A mis en orbite le 3 avril 2014 et Sentinel-1B mis en orbite le 25 avril 2016 (ESA, 2017). L'objectif du programme est de fournir des données complètes et actualisées permettant d'assurer la surveillance de l'environnement. Ces deux satellites sont en orbite héliosynchrone avec une résolution temporelle de 12 jours à l'équateur pour chaque satellite permettant ainsi d'observer une même zone géographique tous les 6 jours. Les données Sentinel-1 sont diffusées librement via la plateforme scientifique *Copernicus* de l'ESA (<https://scihub.copernicus.eu/dhus/>) ou la plateforme d'exploitation des produits Sentinel du CNES (<https://peps.cnes.fr/rocket/#/>). Les images Sentinel-1 sont disponibles selon 3 formats et 2 polarisations telles que présentés dans le Tableau 3.2 :

- Le format *SLC* « *Single Look Complex (SLC)* ».
- Le format *GRD* « *Ground Range Detected (GRD)* ».

Pour les deux zones d'intérêt *T33PUL* dans la partie Nord et *T32NPL* dans la partie Ouest Cameroun, nous avons utilisé l'option de polarisation *VH+VV* du Tableau 3.2.

Le capteur Sentinel-1 fonctionne dans 4 modes d'acquisition telle que montrés dans la Figure 3.10 :

- Le mode *StripMap (SM)*.
- Le mode *Interferometric Wide Swath (IW)*.
- Le mode *Extra-Wide Swath (EW)*.
- Le mode *Wave (WV)*.



Source : <https://dipankar005.wordpress.com/2016/02/07/sar-data-selection-and-different-sar-satellites/>

FIG. 3.10 – Schéma illustratif des modes d'observation des satellites Sentinel-1A/-1B.

Au niveau des deux zones d'intérêt *T33PUL* et *T32NPL*, nous disposons des images Sentinel-1 en polarisation *VH+VV* en mode *IW* avec une taille du pixel au sol ramenée à $10m \times 10m$, un nombre de vues correspond à 4. Des traitements spécifiques sont réalisés sur ces images afin de faciliter l'extraction des informations portant sur l'OCS.

3.2.2 Description des équipements de prise de vues aériennes

La prise de vues a été réalisée à l'aide d'un avion Piper Cheyenne II XL PA 31T 2 avec une chambre photogrammétrique numérique grand format Microsoft Vexcel Ultracam Xp. Cette chambre de dernière génération possède jusqu'à ce jour un des formats les plus larges disponible pour les caméras numériques aériennes grand format (17310×11310 pixels, soit un format d'image de 196 megapixels - taille du pixel de 6 microns - focale de 100,5 mm). La prise de vues a une focale de 100,5 mm, proche de la largeur de son capteur (103,86 mm) et dont le rapport B/H permet de maximiser la précision en 3D. Sa haute sensibilité radiométrique (> 12 bits par canal) lui permet de restituer des images riches en couleurs, nettes, contrastées et précises : il y a beaucoup moins d'objets invisibles dans les zones sombres des clichés, telles que les ombres des bâtiments. Le facteur de pixel couleur pour les pixels panchromatiques est de 1 :3. Dans le cadre des travaux de cette thèse, la prise de vues aériennes avec une sensibilité radiométrique de 8 bits par canal a été récupérée. Les détails de la description des prises de vues aériennes se trouvent en annexe de ce manuscrit.

TAB. 3.2 – Caractéristiques des modes d’acquisition des images Sentinel-1A/-1B (<https://sentinel.esa.int>).

Mode	Angle d’incidence (°)	Taille du pixel au sol (m ²)	Option de polarisation	Poutre d’elevation
<i>StripMap</i>	18,3 - 46,8	5 × 5	<i>HH + HV</i> <i>VH + VV</i> <i>HH, VV</i>	6
<i>Interferometric Wide Swath</i>	29 - 46	5 × 20	<i>HH + HV</i> <i>VH + VV</i> <i>HH, VV</i>	3
<i>Extra-Wide Swath</i>	18,9 - 47	20 × 40	<i>HH + HV</i> <i>VH + VV</i> <i>HH, VV</i>	5
<i>Wave</i>	21,6 - 25,1 / 34,8 - 38	5 × 5	<i>HH, VV</i>	2
<i>Fréquence</i>	5,405 GHz / 5,5 cm			
<i>Bande d’acquisition</i>	<i>Bande C</i>			

3.2.3 Pré-traitements des données satellitaires

Lors de l’acquisition d’une image satellitaire optique, le capteur imageur mesure la quantité d’énergie réfléchiée par la surface de la Terre à l’aide d’un radiomètre. Malheureusement, l’information reçue par le radiomètre n’est pas une mesure précise et uniforme de la surface du sol. En effet, le signal reçu est perturbé par la présence d’erreurs, d’artefacts, de déformations due au processus d’acquisition.

Les pré-traitements des données satellitaires permettent alors d’obtenir des valeurs de réflectance corrigées de ces effets perturbateurs. Ils sont généralement divisés en trois catégories : 1) les corrections géométriques pour rendre superposables les images de la série, 2) les corrections radiométriques pour obtenir des valeurs de réflectance comparables entre les images de la série, et 3) la reconstruction des données manquantes pour faciliter l’utilisation des algorithmes de classification.

3.2.3.1 Pré-traitements des images optiques Sentinel-2 (S-2)

Dans le cas d’études de séries temporelles, les pré-traitements sont un enjeu important afin de pouvoir suivre l’évolution des réflectances d’une date à l’autre et de comparer les valeurs pixel à pixel. Par ailleurs, l’utilisation de différentes tuiles lors de traitements sur de grandes étendues requiert des valeurs de réflectance précises afin d’éviter des effets en bordure de tuile. Enfin, l’utilisation d’algorithmes de classification nécessite des vecteurs de variable qui ne contiennent pas de données manquantes. Les données manquantes apparaissent lors de la présence de nuages, de données saturées et des traitements sur de grandes étendues.

Dans un premier temps, les corrections géométriques et radiométriques sont décrites. Dans un deuxième temps, la problématique liée aux données manquantes est abordée. Une dernière partie détaille le processus de correction appliqué à l’ensemble des images utilisées.

3.2.3.1.1 Corrections géométriques et radiométriques Les distributeurs d'images satellitaires appliquent généralement d'abord les corrections géométriques, puis les corrections radiométriques. En suivant cet ordre, les deux types de correction sont détaillés dans la suite (l'Annexe A.4 donne en exemple, les différents niveaux de pré-traitements appliqués aux images Sentinel-2).

Corrections géométriques

Les images issues du satellite ne sont pas directement superposables à une carte. En effet, des déformations géométriques sont introduites, dues au positionnement du satellite sur son orbite, aux effets du relief terrestre, à la rotondité de la Terre et à sa rotation pendant la prise de vue. Des distorsions peuvent aussi être ajoutées en fonction des conditions d'acquisition, *e.g.* le mouvement du satellite et l'angle d'acquisition. Les corrections géométriques sont appliquées afin de réduire l'ensemble de ces déformations introduites lors de l'enregistrement des images. Elles servent également à ortho-rectifier les images, *i.e.* les rendre superposables, et à les géo-référencer, *i.e.* leur donner une localisation en latitude et longitude précise.

Afin d'appliquer les corrections géométriques, un modèle géométrique est élaboré en fonction de la position du satellite, de ses lois d'altitude ou encore de l'angle de visée. Il permet de rendre superposables les images à une carte. Afin d'augmenter sa précision, des points d'appuis sont utilisés pour corriger les erreurs dues au positionnement du satellite sur son orbite et les effets du relief terrestre. Ils sont localisés en longitude et latitude grâce à une image de référence elle-même bien localisée au sol, et en altitude grâce à un Modèle Numérique de Terrain (*MNT*).

Corrections radiométriques

Le signal reçu par le radiomètre contient la lumière renvoyée par le paysage, mais aussi la lumière du Soleil, les différentes réflexions atmosphériques et du bruit ajouté par le capteur. Les capteurs passifs ne peuvent donc pas mesurer de manière précise et uniforme la quantité d'énergie réfléchiée par les objets situés à la surface de la Terre. D'une part, la lumière solaire qui éclaire ces objets est perturbée par la traversée de l'atmosphère et n'éclaire pas tous les objets sous un même angle. Comme les données utilisées dans ces travaux sont acquises à angle constant et aux mêmes heures de passage, cette problématique est atténuée. Les différences radiométriques observées sont alors dues à l'acquisition de la série temporelle à différentes saisons. D'autre part, la lumière réfléchiée par les paysages est perturbée par la traversée de l'atmosphère. Le capteur Sentinel-2 possède certaines bandes spectrales acquises avec une basse résolution spatiale qui aident à identifier certains paramètres de l'atmosphère.

Les corrections radiométriques consistent alors à transformer le signal reçu par le capteur en une valeur radiométrique la plus proche possible de celle mesurée au sol. L'objectif de ces corrections est donc de convertir les valeurs brutes des images, appelées comptes numériques, en réflectance *Top of Canopy* (*TOC*). La Figure 3.11 montre les différentes étapes des corrections radiométriques.

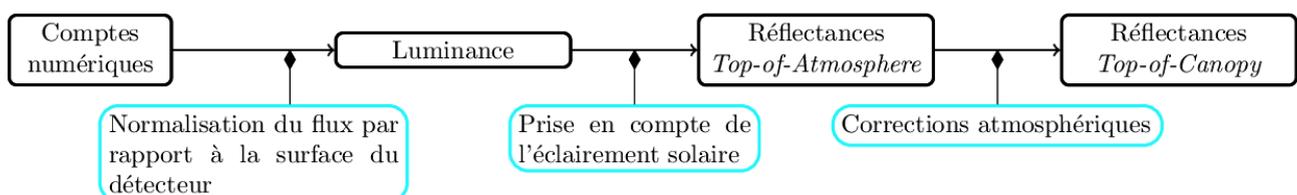


FIG. 3.11 – Corrections radiométriques : des comptes numériques aux réflectances *TOC*.

La première étape consiste à convertir les comptes numériques en luminance. Cette dernière représente le flux lumineux normalisé par rapport à la surface du détecteur. La luminance est donc une mesure physique indépendante des caractéristiques du radiomètre utilisé.

La deuxième étape consiste à normaliser la luminance en réflectance *Top of Atmosphere* (TOA). Pour ce faire, l'angle d'acquisition du satellite et l'éclairement solaire incluant l'irradiance solaire et l'angle solaire zénithal est pris en compte.

La troisième et dernière étape consiste à transformer les réflectances TOA en réflectance TOC en corrigeant les effets du passage de la lumière réfléchiée dans l'atmosphère (HAGOLLE et al., 2008). Cette étape est connue comme celle des corrections atmosphériques. Elle nécessite de caractériser le plus précisément possible les conditions atmosphériques, comme la pression atmosphérique, le taux d'humidité, la quantité de vapeur d'eau ou encore l'épaisseur optique des aérosols. Comme ces caractéristiques dépendent fortement des longueurs d'onde, et qu'elles varient dans le temps et l'espace, ces informations doivent être acquises par des capteurs spécifiques, pas toujours présents sur les zones étudiées. Ainsi, les corrections atmosphériques ne peuvent pas toujours être appliquées.

Finalement, une dernière étape, non-indiquée dans la Figure 3.11, consiste à corriger les variations d'éclairement dues au relief : les effets de pente. Ces corrections cherchent à réduire les différences de réflectance observées par exemple sur des versants opposés. Elles sont particulièrement intéressantes lors de traitements en zones montagneuses.

3.2.3.1.2 Données manquantes Outre les déformations géométriques et les erreurs dues au processus d'acquisition, les données optiques Sentinel-2 sont perturbées par la présence de données manquantes. Ces données manquantes correspondent à des pixels pour lesquels les valeurs de réflectance de la surface au sol ne sont pas disponibles à cause soit de la couverture nuageuse et des problèmes de saturation, soit des dates d'acquisitions irrégulières.

Reconstruction des données manquantes

Concernant les données nuageuses et saturées, une première solution consiste à travailler avec toutes les images sans prendre de précaution par rapport aux données manquantes. Les vecteurs de variables sont alors erronés, *i.e.* certaines valeurs de réflectance ne représentent pas la surface au sol.

Une deuxième solution consiste à considérer seulement les images non-nuageuses et non-saturées en entrée du système de classification. Si l'image n'est pas entièrement nuageuse et saturée, cette solution est sous-optimale à cause de la perte d'informations que les données non-nuageuses et non-saturées pourraient apporter. De plus, la série temporelle serait composée d'un faible nombre d'images car la majorité des images contient des nuages ou des pixels saturés.

Une troisième solution consiste alors à reconstruire les données manquantes en retrouvant les valeurs de réflectance : c'est le *gap-filling*. Cette reconstruction est réalisée en amont de la phase d'apprentissage. Pour ce faire, les données manquantes sont tout d'abord détectées.

Une autre solution proposée et appliquée dans le cadre de cette thèse consiste à calculer des synthèses mensuelles de séries temporelles d'images Sentinel-2 qui peuvent constituer une alternative au *gap-filling* pour gérer les données manquantes.

De nombreuses méthodes de détection des données nuageuses existent. La méthode utilisée dans ces travaux tire bénéfice de la haute résolution temporelle des images acquises en repérant les variations de réflectance entre les acquisitions consécutives (HAGOLLE et al., 2010). La présence de nuages dans

les images modifie fortement les valeurs de réflectance dans la bande bleue, alors que les valeurs de réflectance sont normalement stables pour des acquisitions rapprochées. Cette approche est adaptée pour les images provenant d'acquisition à angle de vue constant comme Sentinel-2. La géométrie identique des images et l'heure de passage constante renforce la stabilité des valeurs de réflectance pour les données non-nuageuses et non-saturées entre deux acquisitions successives.

Une fois les données manquantes détectées, la reconstruction est réalisée dans ces travaux de thèse en appliquant une interpolation temporelle linéaire. Pour chaque donnée manquante, les valeurs de réflectance aux dates valides avant et après la date à reconstruire sont utilisées pour appliquer l'interpolation linéaire. Parfois une seule date est valide dans le profil. Dans ce cas là, la valeur de réflectance de cette date valide est répétée pour toutes les autres dates. Le choix de l'interpolation linéaire permet de gérer plus facilement les gros volumes de données induit par le traitement des séries temporelles d'images satellitaires à hautes résolutions⁷. Par ailleurs, l'utilisation de méthodes d'interpolation plus complexes comme les splines ou le filtre de Savitzky-Golay a montré peu de différence sur les performances obtenues en classification (RODES, 2016).

Harmonisation temporelle

Une deuxième difficulté survient lors de traitements sur de grandes étendues. En effet, différents passages du satellite sont nécessaires pour cartographier de grandes étendues. Ainsi, toutes les zones ne sont pas acquises aux mêmes dates. Afin d'utiliser les algorithmes de classification, les vecteurs de variables doivent avoir la même taille et chaque variable doit représenter la même information. Dans la réalité, tous les pixels ne sont pas vus au même moment et le même nombre de fois, un pixel n'étant vu que lorsqu'il n'est ni nuageux ni saturé lors d'une acquisition. Même en cas de reconstruction des données nuageuses et saturées, les vecteurs de variables auront toujours des tailles différentes lors de l'utilisation de plusieurs tuiles. Ces différences sont problématiques puisque les algorithmes de classification ont besoin d'échantillons décrits par des vecteurs de variables de tailles identiques. Afin de s'affranchir de ce problème, il est nécessaire d'harmoniser temporellement les vecteurs de variables pour qu'ils représentent les mêmes dates. Pour ce faire, une interpolation temporelle linéaire est réalisée sur un même vecteur de dates. Cette interpolation a peu de conséquences sur les performances des algorithmes de classification (INGLADA et al., 2015b).

3.2.3.1.3 Traitements appliqués Dans l'ensemble de ces travaux de thèse, les images utilisées sont orthorectifiées, en réflectance *TOC* et corrigées des effets de pente. Plus précisément, les images Sentinel-2 sont fournies par le pôle de données et de services surfaces continentales THEIA. Cet organisme ortho-rectifie les images, et effectue les deux premières étapes des corrections radiométriques indiquées par la Figure 3.11. Ainsi, les images téléchargées sont corrigées géométriquement et en réflectance *TOA*.

Le passage en réflectance *TOC* est ensuite réalisé avec la chaîne de traitement *MACCS ATCOR Joint Algorithm (MAJA)* (HAGOLLE et al., 2015a). Cette chaîne permet d'obtenir les images en réflectance

7. A titre d'exemple, une image Sentinel-2 téléchargée sur la Plateforme d'Exploitation des Produits Sentinel (peps.cnes.fr) – treize bandes spectrales corrigées géométriquement, en réflectance *TOC* et corrigées des effets de pente – couvrant $100 \times 100 \text{ km}^2$ occupe 6,6 Go d'espace disque. Et une série temporelle Sentinel-2 de la France pour une année, composée en moyenne de 35 images avec dix bandes spectrales échantillonnées à 10 mètres, occupent 19 To sur l'espace disque.

TOC corrigées des effets de pente, les masques des nuages (avec leurs ombres) et les masques des données saturées comme décrit à la Section 2.7.1.

Le traitement des données manquantes est ensuite spécifique à chacune des zones d'étude *ZONE1* et *ZONE2*. Il dépend principalement du nombre d'images et de tuiles utilisées. Le reste des pré-traitements appliqués est détaillé par zone d'étude.

La première zone d'étude (*ZONE1*), représentée dans la Figure 3.4, est composée d'une année (01-01-2018 au 01-01-2019) de chacune des deux différents types d'images optiques et radar soient respectivement 105 et 105 images Sentinel-1 et Sentinel-2 acquises uniquement sur la tuile *T33PUL* (première zone d'intérêt (Figure 3.5)) telle que présenté dans le Tableau A.1 et d'une année d'un seul type d'images optiques soient 200 images Sentinel-2 acquises sur les cinq autres tuiles montrées dans le Tableau A.4 qui couvrent l'ensemble de cette zone d'étude. La Figure 3.12 illustre l'emprise des deux différents types d'images utilisés après orthorectification sur la première zone d'intérêt (*T33PUL*).

Concernant les images radar, deux scènes correspondant aux deux orbites 80 et 161 sur la tuile *T33PUL* sont retenues et une année (01-01-2018 au 01-01-2019) d'images Sentinel-1 sont utilisées pour chacune des scènes qui couvre la première zone d'intérêt.

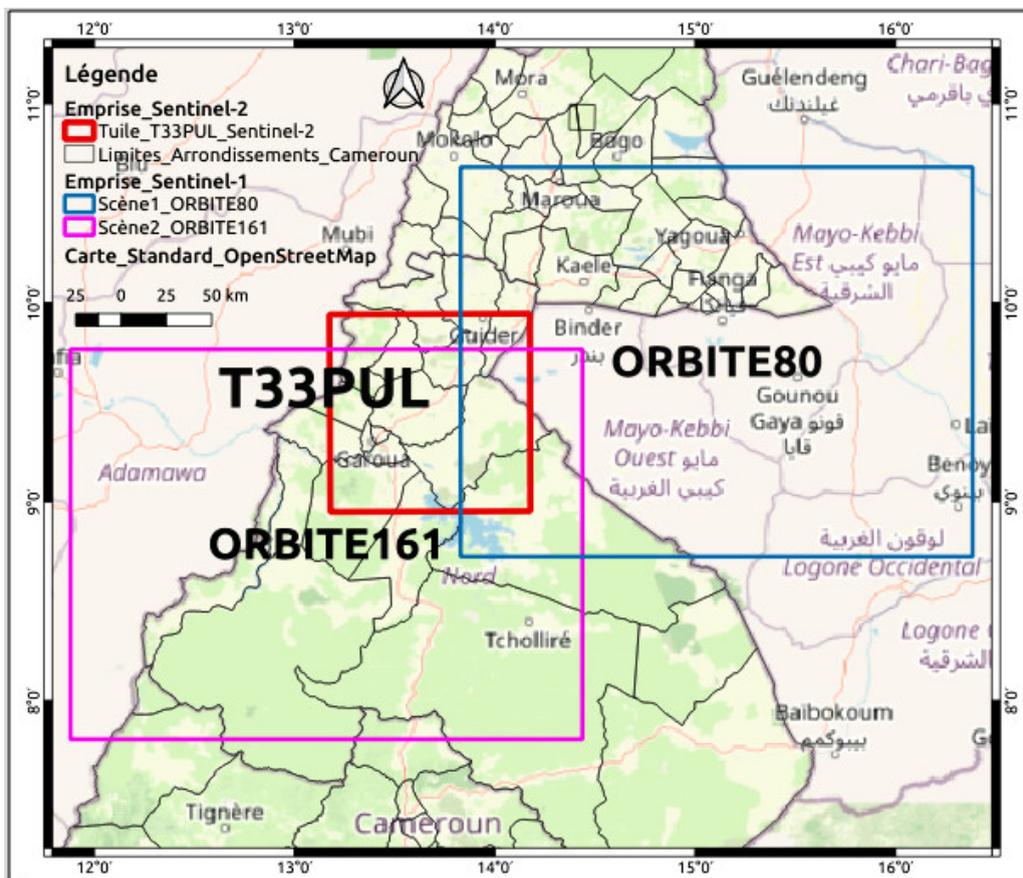


FIG. 3.12 – Emprises des images Sentinel-1/-2 sur la première zone d'intérêt *T33PUL*.

S'agissant de la deuxième zone d'étude (*ZONE2*), représentée dans la Figure 3.7, elle est composée d'une année (01-01-2018 au 01-01-2019) de chacune des deux différents types d'images optiques et radar soient respectivement 47 et 28 images Sentinel-1 et Sentinel-2 acquises uniquement sur la tuile *T32NPL* (deuxième zone d'intérêt (Figure 3.8)) telle que présenté dans le Tableau A.3 et d'une année

d'un seul type d'images optiques soient 512 images Sentinel-2 acquises sur les onze autres tuiles montrées dans les Tableaux A.5 et A.6 pour les six premières restantes et les Tableaux A.7 et A.8 pour les cinq autres tuiles qui couvrent l'ensemble de cette zone d'étude. La Figure 3.13 illustre l'emprise des deux différents types d'images utilisés après orthorectification sur la zone *T32NPL*.

Une seule scène d'image radar correspondant à l'orbite 51 est retenue sur la tuile *T32NPL* et une année (01-01-2018 au 01-01-2019) d'images Sentinel-1 est utilisée sur cette scène.

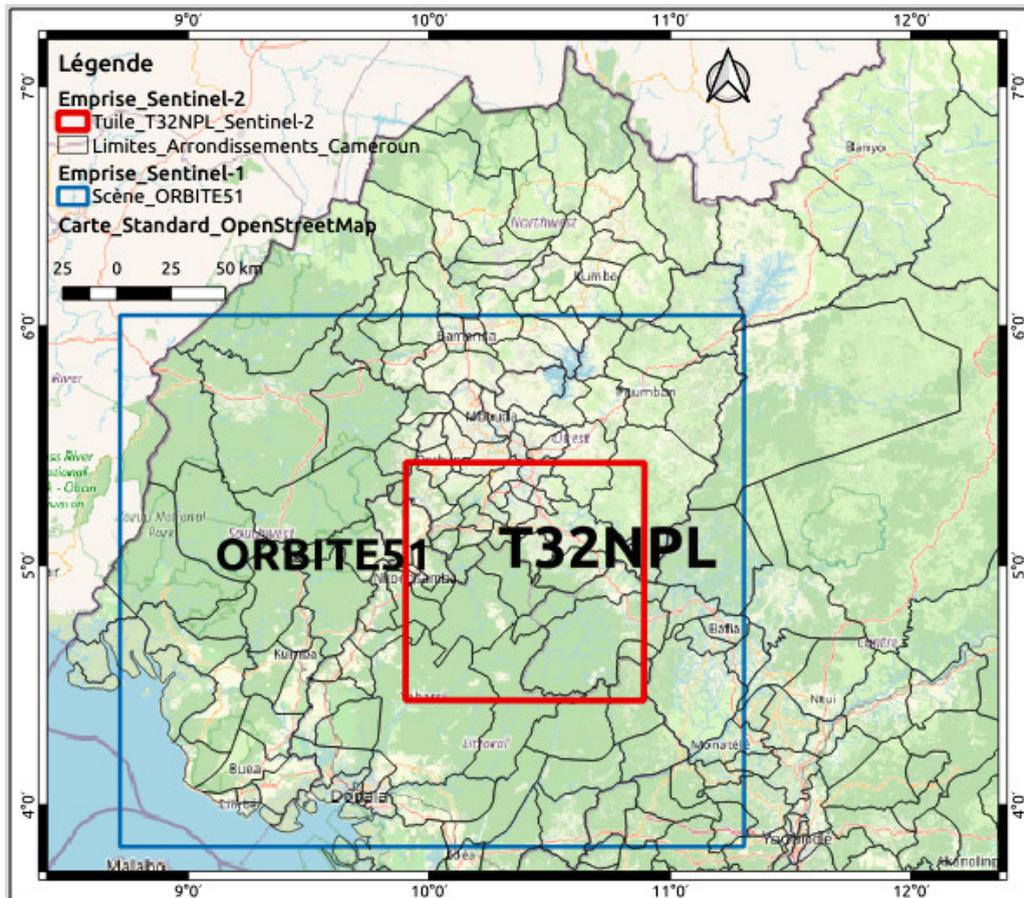


FIG. 3.13 – Emprises des images Sentinel-1/-2 sur la deuxième zone d'intérêt *T32NPL*.

Dans les deux zones d'étude, seules les bandes spectrales à une résolution spatiale de 10 et 20 mètres de Sentinel-2 sont gardées. Les bandes à 20 mètres sont ré-échantillonnées à 10 mètres en utilisant une méthode d'interpolation spatiale bicubique dans la chaîne de traitement *iota*². Les bandes spectrales à 10 mètres de résolution spatiale d'images radar Sentinel-1 en *GRD* et d'amplitudes réelles acquises uniquement dans le mode *IW* ont été gardées. Par la suite, ces images radar ont été ortho-rectifiées sur les grilles d'images Sentinel-2 par un processus automatique fondé sur le *S1-Tiling*⁸ à l'intérieur de la chaîne de *iota*² afin de pouvoir les y traiter conjointement avec les images optiques Sentinel-2.

Afin de réduire davantage les effets causés par la présence des nuages (avec leurs ombres) dans les images optiques Sentinel-2 (particulièrement dans la *ZONE2*) qui contiennent ainsi des données manquantes dues à la technologie de l'imagerie satellitaire optique qui utilise la lumière du Soleil pour réaliser les images (méthode passive), nous avons eu recours à l'imagerie satellitaire radar qui est un système actif émettant des ondes qui interagissent directement avec la surface du sol avant de revenir

8. <https://peps.cnes.fr>.

vers le satellite permettant ainsi de réaliser des mesures en tout temps (conditions météorologiques) de jour comme de nuit. Pour étudier (quantifier) leur apport au niveau des résultats des expériences de classification et fusion produites, nous avons utilisé des images radar Sentinel-1 conjointement avec les images optiques Sentinel-2 uniquement sur les deux zones d'intérêt *T33PUL* et *T32NPL*. Ces images radar Sentinel-1 ont préalablement été pré-traitées.

3.2.3.2 Pré-traitements des images radar Sentinel-1 (S-1)

Les images radar Sentinel-1 que nous avons utilisées ont subi plusieurs pré-traitements avec le logiciel *SeNtinel Application Platform (SNAP)* détaillé à la Section 2.7.2. Ces étapes montrées dans la Figure 3.14 sont généralement divisées en sept catégories conçues pour réduire au mieux les erreurs de propagation dans la suite des processus décrits ci-après. Le code à exécuter pour le processus de pré-traitement est disponible sur le dépôt *GitHub* (FILIPPONI, 2019) : 1) l'application du fichier d'orbite, 2) la suppression du bruit thermique, 3) la suppression du bruit en bordure, 4) l'étalonnage, 5) le filtrage du chatoiement, 6) la correction de la distance Doppler du terrain, et 7) la conversion des informations d'intensité en décibel.

3.2.3.2.1 Application du fichier d'orbite Les vecteurs d'état d'orbite, contenu dans les informations de métadonnées des produits Sentinel-1 SAR, ne sont généralement pas précises. Les orbites précises des satellites n'étant déterminées qu'après plusieurs jours et disponibles pendant des jours voir des semaines après la génération du produit. L'opération disponible dans le logiciel *SNAP* et qui consiste à appliquer une orbite précise permet de télécharger et mettre à jour automatiquement les vecteurs d'état d'orbite dans les métadonnées de chaque scène d'images Sentinel-1 fournissant ainsi une position précise du satellite et une information sur sa vitesse.

3.2.3.2.2 Suppression du bruit thermique L'intensité des images Sentinel-1 est perturbée par du bruit thermique additif particulièrement dans le canal composé à partir des deux polarisations *VH* et *VV* (PARK, KOROSOV et BABIKER, 23-28 avril 2017). La suppression du bruit thermique réduit ses effets en particulier dans la texture interne des fauchées normalisant ainsi la rétrodiffusion du signal dans l'ensemble de la scène Sentinel-1 et résultant en une réduction des discontinuités entre les bandes des scènes en modes d'acquisition à plusieurs bandes. L'opérateur de suppression du bruit thermique des données Sentinel-1 disponible dans le logiciel *SNAP*, peut à son tour re-introduire le bruit du signal qui pourrait avoir été supprimé durant la génération du produit de niveau 1, et les annotations de mise à jour du produit permettant de ré-appliquer la correction (SOFTWARE, 1 mai 2018). Les produits Sentinel-1 de niveau 1 fournissent des tableaux de recherche de bruit *look-up table (LUT)* en puissance linéaire pour chaque jeu de données de mesure et utilisés pour déduire les profils de bruit calibrés correspondant aux données *GRD* calibrées (SOFTWARE, 1 mai 2018).

3.2.3.2.3 Suppression du bruit en bordure Tout en générant les produits de niveau 1, il est nécessaire de corriger le temps de début d'échantillonnage afin de compenser le changement de courbure de la Terre. Dans le même temps, la compression de plage et d'azimut conduit aux artefacts radiométriques aux différentes frontières des images. L'algorithme de suppression du bruit en bordure (GAUILLAUME, 2015), disponible en opérateur du logiciel *SNAP*, était conçu pour supprimer les bruits de faible intensité et les données invalides sur les bords de la scène.

3.2.3.2.4 Étalonnage Les images Sentinel-1 utilisées sont des produits *GRD* dont les comptes sont enregistrés en valeur numérique. La calibration radiométrique consiste à convertir des valeurs numériques en variable physique du coefficient de rétrodiffusion (σ^0) radar en supposant le terrain horizontal plat. Une table de correspondance dépendant de l'angle de visée distale permet d'obtenir la valeur physique du coefficient de rétrodiffusion (σ^0). Cette opération est réalisée pour les deux polarisations *VV* et *VH*. Ainsi on obtient après calibration radiométrique la valeur physique du coefficient de rétrodiffusion radar en supposant le terrain horizontal plat. En cas de terrain avec relief, on observe sur les images les effets de relief discutés dans la Section 2.1.2 sur les images radar.

L'organigramme de la Figure 3.14 décrit l'ensemble du processus de pré-traitements réalisé sur les images C-SAR Sentinel-1 utilisées au cours des travaux.

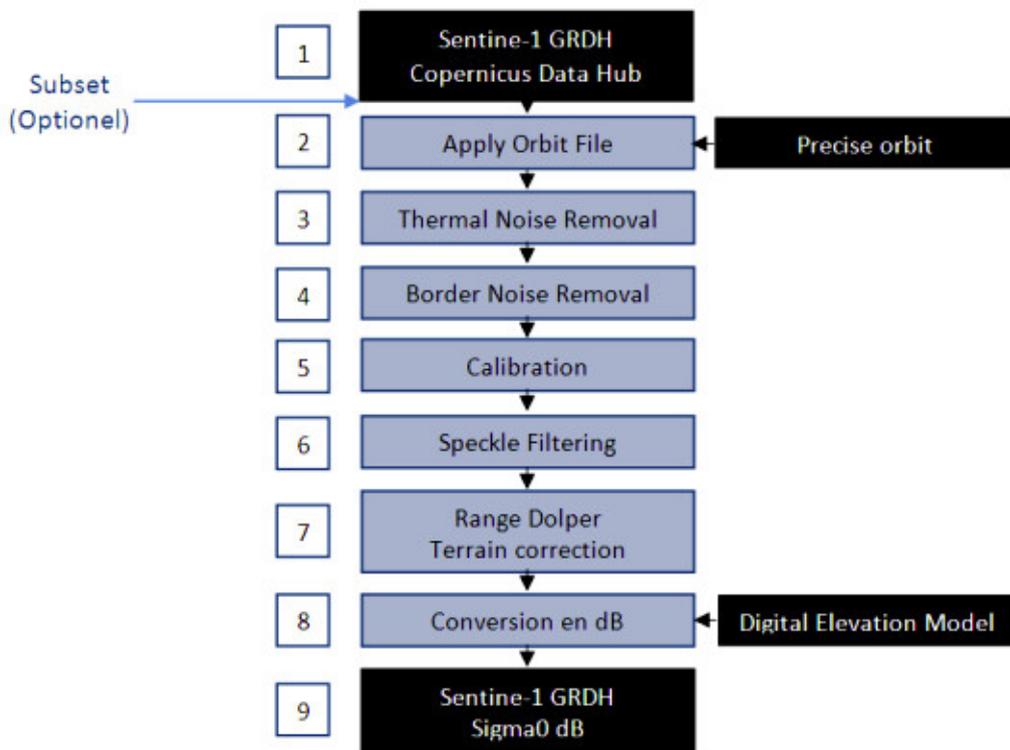


FIG. 3.14 – Pré-traitements réalisés sur les images Sentinel-1

3.2.3.2.5 Filtrage du chatolement Comme nous l'avons évoqué dans la Section 2.1.2, les images satellitaires radar présentent un phénomène appelé chatolement qui les dégrade à la manière d'un bruit et les rend dans la plupart des cas non utilisables en l'état. Pour rappel, le chatolement est causé par des interférences constructives, destructives et aléatoires des ondes réfléchies de façon dispersée par les diffuseurs élémentaires au sein de chaque cellule de résolution (ELACHI, 1988). La présence du chatolement réduit ainsi la lisibilité de l'image et rend plus difficile l'extraction de l'information. Il est donc utile de réduire dans certains cas, l'effet du chatolement avant l'interprétation et l'analyse des images. Pour ce faire on utilise le filtrage des images. L'enjeu du filtrage est de préserver les contours tout en améliorant la radiométrie par réduction de la variabilité du chatolement. Il existe plusieurs stratégies de filtrage parmi lesquelles : 1) le filtrage statique local de Lee, 2) le filtrage spatial simple appelé Boxcar (ou traitement multi-vues), 3) le filtrage spatio-temporel, et 4) le filtrage temporel.

Filtre de Lee

Le filtre de Lee est capable de lisser le bruit dans les régions plates en laissant des détails fins tels que les lignes inchangés. Il utilise de petites fenêtres (3×3 , 5×5 ou 7×7). Dans chaque fenêtre, la moyenne et la variance locales sont respectivement estimées de la manière suivante :

$$\bar{x} = \frac{1}{N} \sum_{i=1}^N x_i. \quad (3.1)$$

$$\sigma_x^2 = \frac{1}{N-1} \sum_{i=1}^N (x_i - \bar{x})^2. \quad (3.2)$$

Dans les régions sans activité de signal, le filtre produit la moyenne locale (\bar{x}). Lorsqu'une activité est détectée, le filtre de Lee transmet le signal d'origine sans le modifier :

$$F(x_1, \dots, x_N) = \beta x_1 + (1 - \beta) \bar{x}, \quad (3.3)$$

où x_1 représente le pixel central dans la fenêtre. Le paramètre β varie entre 0 (pour les régions plates) et 1 (pour les régions à fortes activités du signal). Dans le cas particulier de bruit additif, le paramètre β s'exprime par la formule suivante :

$$\beta = \max\left(\frac{\sigma_x^2 - \sigma_{12}^2}{\sigma_x^2}, 0\right), \quad (3.4)$$

où σ_{12}^2 est une estimation de la variance du bruit entre deux pixels centrés aux positions 1 et 2.

Le filtrage statique local est plus approprié dans des régions d'intensité constante du signal et le filtre de Lee détecte mieux du bruit en répondant par lissage. En revanche, le filtre de Lee arrête son lissage dans des régions qui contiennent une activité du signal telle que des lignes et des bords. Le filtre de Lee peut ainsi lisser les régions plates tout en préservant les détails intacts. Son inconvénient majeur est qu'il laisse du bruit au voisinage des arêtes et des lignes comme montrés dans la Figure 3.15. Les variantes du filtre de Lee comme par exemple le filtre de Lee raffiné sont capables de gérer le bruit multiplicatif ainsi que la netteté.

Filtre Boxcar

Le filtre Boxcar effectue une moyenne sur un voisinage de taille fixe sur l'ensemble de l'image. C'est une application directe de la moyenne glissante utilisée pour les images. La taille et la forme de la fenêtre sont fixes sur toute l'image. Ce filtre dégrade la résolution spatiale au profit de la résolution radiométrique (diminution du chatoiement).

Filtre temporel

Le filtre temporel est une simple moyenne ou un filtre médian, appliqué à l'intensité d'une série temporelle de pixels d'une même polarisation. Le filtre temporel nécessite plusieurs acquisitions dans la même géométrie.

Filtre spatio-temporel

Le filtre spatio-temporel nécessite plusieurs acquisitions dans la même géométrie d'acquisition. Ce filtre dégrade peu la résolution spatiale, conserve les contours et les informations temporelles tout en réduisant le chatoiement. Dans le cadre des travaux de cette thèse, nous avons utilisé le filtrage statique local de Lee avec une petite fenêtre de 3×3 pour pré-traiter les images Sentinel-1 à l'étape

6 (Figure 3.14). Ce filtre permet d'améliorer la qualité des données à partir d'une séquence sur une même zone acquise dans la même géométrie. Il utilise une moyenne spatiale et temporelle pondérée donnant une plus grande importance à la date filtrée dans la polarisation considérée. Ainsi s'il y a au total 10, 20 ou 55 scènes d'image dans la même géométrie d'acquisition avec la même polarisation, après l'application du filtre de Lee on obtient à la sortie 10, 20 ou 55 scènes filtrées.

La Figure 3.15 présente l'illustration en polarisation *VV* du résultat du filtre de Lee sur l'image du 04/07/2018 d'une pile de 43 images Sentinel-1 avec une fenêtre spatiale de 7×7 pixels sur la première zone d'intérêt (*T33PUL*) dans la zone d'étude Nord (*ZONE1*).

3.2.3.2.6 Correction de la distance Doppler du terrain Les images radar Sentinel-1 sont généralement détectées avec un angle de vue variable supérieur à zéro degré entraînant une certaine distorsion des images liée à la géométrie latérale. Les corrections de terrain ont pour but de compenser ces distorsions de manière à rendre la représentation géométrique de l'image le plus proche possible de la réalité. La correction de la distance Doppler du Terrain est une correction des distorsions géométriques causées par la topographie telles que les raccourcis et les ombres à l'aide d'un Modèle Numérique d'Elevation (*MNE*) pour corriger la localisation de chaque pixel. L'opérateur de correction de distance Doppler du terrain disponible dans le logiciel *SNAP* implémente la méthode d'ortho-rectification de la distance Doppler (SMALL et SCHUBERT, 2008) pour géo-coder des scènes d'images Sentinel-1 en géométrie radar. Il utilise les informations du vecteur d'état d'orbite disponibles dans les métadonnées, le temps d'annotation du radar, et les paramètres de conversion de la distance oblique-sol avec la référence de données du *MNE* pour déduire les informations de géo-localisation précise (SOFTWARE, 1 mai 2018). Le système de coordonnées de référence (*SCR*) peut être sélectionné et éventuellement défini de manière à correspondre à la zone *UTM* de recouvrement avec les scènes d'images Sentinel-2 comme c'est le dans nos travaux. Cet opérateur permet également de sélectionner la méthode de ré-échantillonnage voulue ainsi que l'espacement entre les pixels de l'image dans le *SCR* choisi. Cette étape de traitement correspond au co-enregistrement (ortho-rectification) des produits *GRD* d'images Sentinel-1 sur les grilles de produits *MSI* d'images Sentinel-2 dans le but de géo-localiser les deux différents types de données sur une grille spatiale commune et promouvoir ainsi l'utilisation des constellations virtuelles de satellites dans le cadre d'une étude conjointe.

3.2.3.2.7 Conversion des informations d'intensité en décibel La visualisation et l'interprétation des images se trouvent dans certains cas facilitées par une transformation logarithmique des données calibrées, ortho-rectifiées et filtrées. Cette information permet de réduire l'étalement de la dynamique des fortes valeurs d'intensités (ou d'amplitudes) et d'augmenter la dynamique des faibles valeurs de celles-ci. Mais cette opération n'est pas indispensable pour comparer des sources distinctes.

$$\sigma_{dB}^o = 10 \log(\sigma^o). \quad (3.5)$$

Afin d'interpréter visuellement les images, nous avons réalisé une composition colorée avec la polarisation *VV* (en décibel) dans le canal *rouge*, la polarisation *VH* (en décibel) dans le canal *vert* et la différence entre les polarisations *VH* et *VV* (en décibel) dans le canal *bleu*.

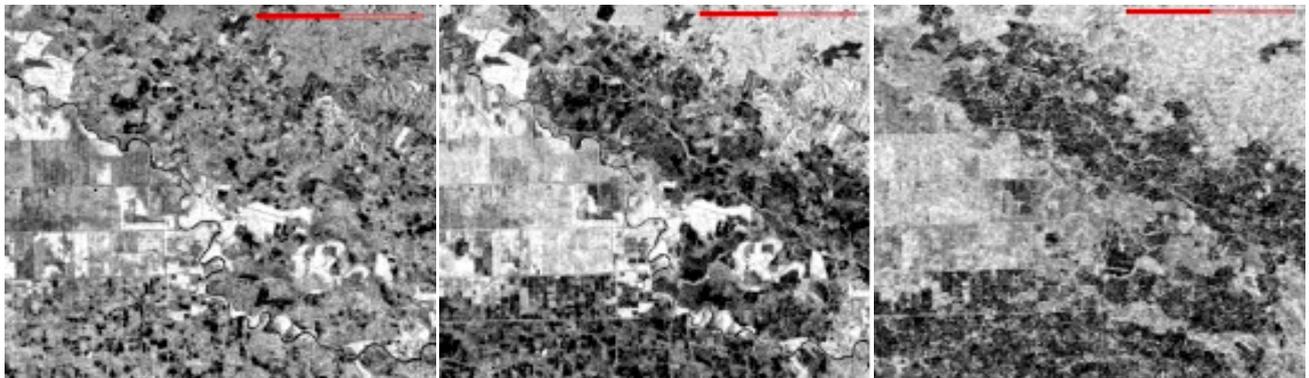


(A) Avant application du filtre de Lee



(B) Après application du filtre de Lee

FIG. 3.15 – Illustration de l'application du filtre de Lee sur la bande VV en décibel de l'image du 04/07/2018 parmi les 43 images Sentinel-1 sur la zone d'intérêt T33PUL.



(A) Canal Rouge = Polarisation VV en dB (B) Canal Vert = Polarisation VH en dB (C) Canal Bleu = Polarisation $VH-VV$ en dB

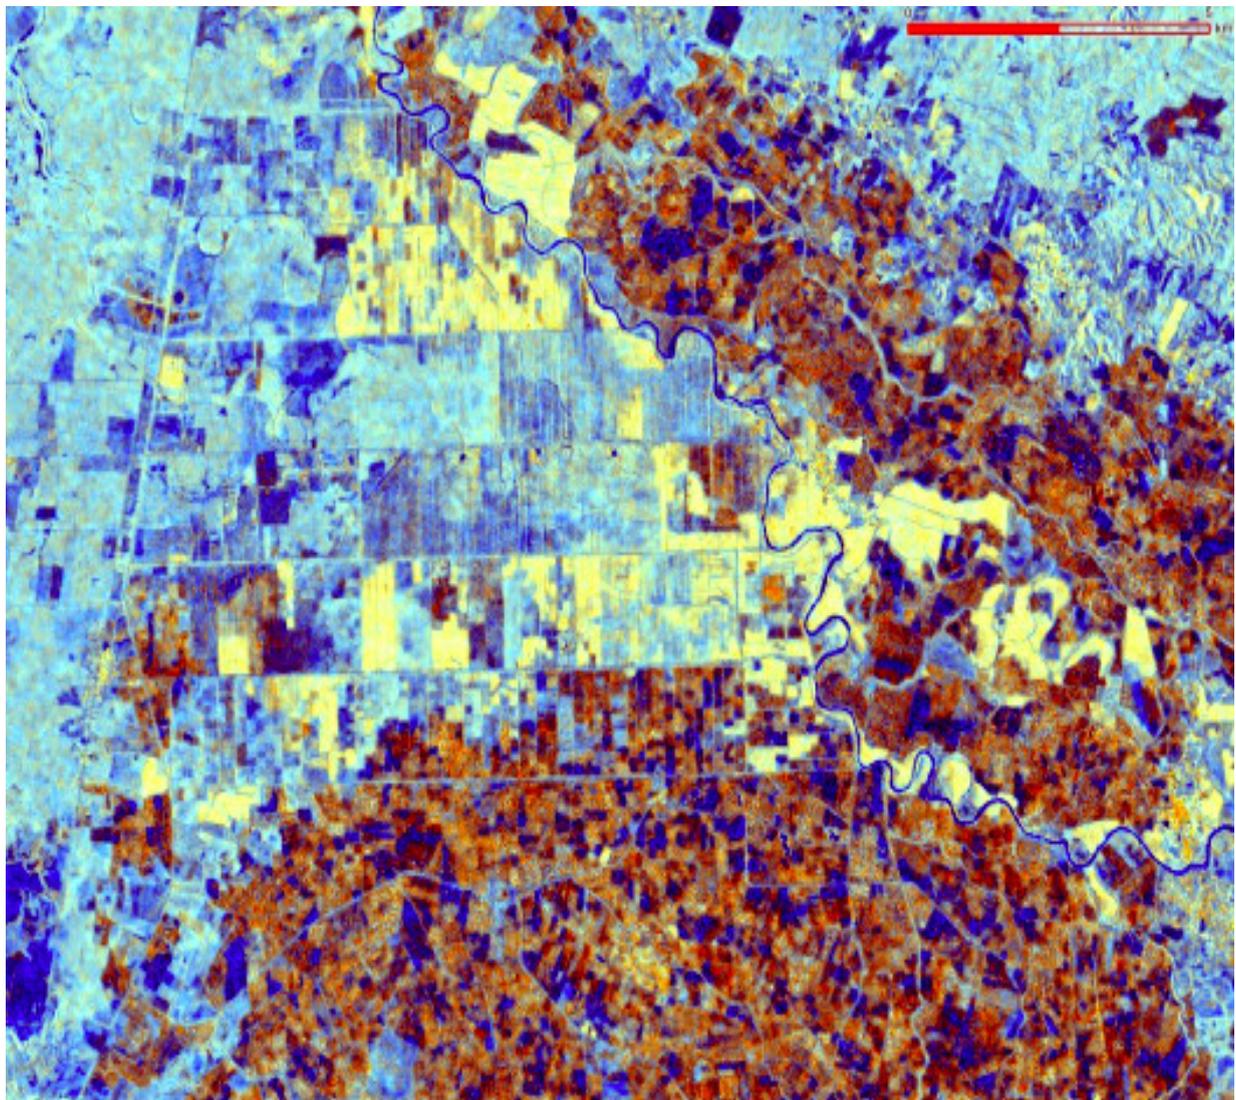


FIG. 3.16 – Illustration de la composition colorée d'une image Sentinel-1 en décibel du 10/06/2018 sur la zone d'intérêt *T33PUL*.

3.2.4 Génération de synthèses mensuelles d'images Sentinel-2

La plupart des méthodes de traitement d'images exigent d'utiliser, pour chaque pixel, celui correspondant à la date la plus favorable pour ce pixel. La sélection est faite à partir de plusieurs critères, et le but est de sélectionner le pixel qui a le moins de chance d'être couvert par un nuage ou une ombre de nuage. Comme ces méthodes travaillent pixel par pixel, les valeurs des pixels contigus peuvent provenir de dates différentes, ce qui entraîne l'apparition d'artefacts lors du passage d'une date à l'autre. La Figure 3.17 montre un exemple de comparaison d'une méthode basée sur le meilleur pixel (critère classique du *NDVI maximum*) avec notre méthode de moyenne pondérée. L'image de droite représentant une moyenne pondérée est beaucoup moins bruitée.

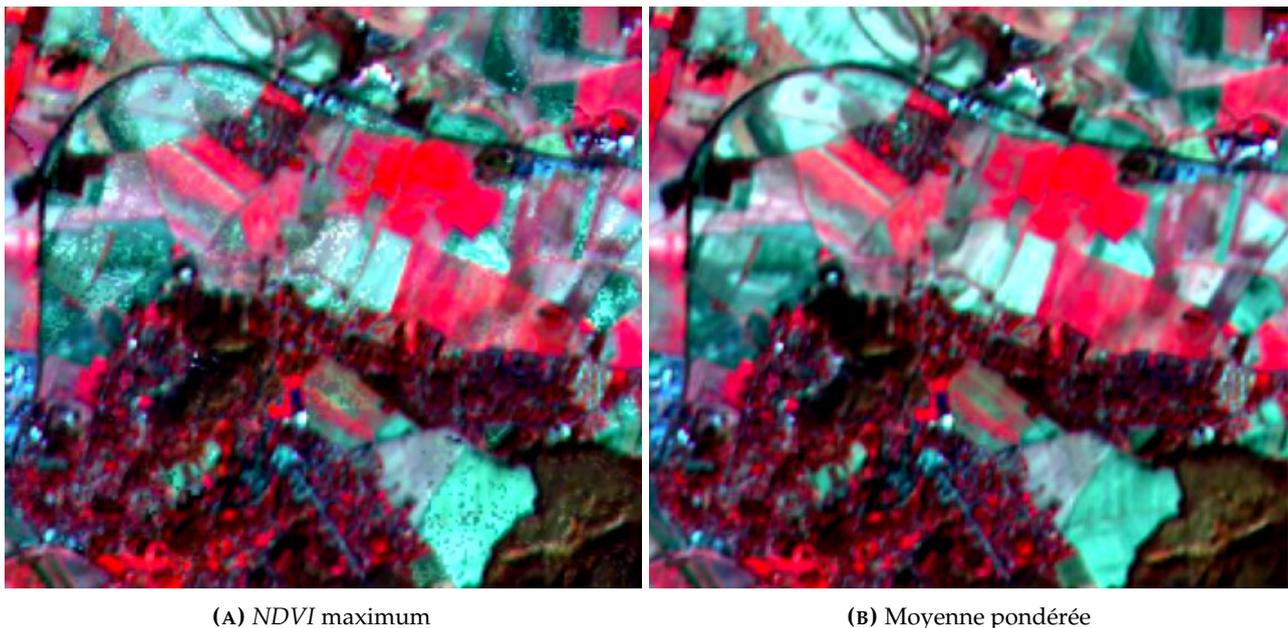


FIG. 3.17 – Comparaison d'une méthode basée sur le meilleur pixel (*NDVI maximum*) avec la méthode de moyenne pondérée.

La production des synthèses de niveau 3A (*Level 3A (L3A)*) s'appuie sur la chaîne *WASP* détaillée à la Section 2.7.2. Cette chaîne utilise comme entrée des produits de niveau 2A (*Level 2A (L2A)*) qui sont fournis après traitement des produits de niveau 1C (*Level 1C (L1C)*) par le logiciel *MAJA* détaillée également à la Section 2.7.2. Sans être parfaite, la qualité des masques de nuages et des masques d'ombre et des masques de neige et d'eau, des produits de niveau L2A que fournit le logiciel *MAJA* permet de ne plus avoir à utiliser un critère supplémentaire pour supprimer les nuages. Il suffit d'écarter les données classées comme ombres ou nuages. Ainsi, la chaîne *WASP* a été conçu pour minimiser les artefacts habituellement visibles sur les coosites mensuels.

Pour chaque pixel et bande spectrale, *WASP* calcule une moyenne des réflectances de surface observées par ciel clair pendant 45 jours. Par exemple, la synthèse du 15 juillet moyennera les observations sans nuages collectées entre le 26 juin et le 5 août. Et ceci est répété chaque mois.

1. Une correction des effets directionnels⁹ permet de faire comme si les images avaient été prises depuis la verticale et d'éviter d'observer des différences sur le bord des emprises des images Sentinel-2.

9. <https://labo.obs-mip.fr/multitemp/>.

2. Des poids sont calculés :

- Les pixels proches d'un nuage ou d'une ombre ont un poids plus faible.
- Les pixels acquis avec un jour clair sans aérosols ont un poids plus fort.
- Les images aux dates proches de la date centrale de la période de synthèse (le 15 juillet dans l'exemple ci-dessus) ont un poids plus élevé.

3. Sur la base de ces poids, une moyenne pondérée des réflectances est calculée.

Il n'est pas toujours possible d'avoir une observation claire pour chaque pixel en 45 jours. Dans ce cas, les synthèses de niveau *L3A* fournit un pixel nuageux, dont la nature est indiquée dans un masque. De même quelques petits nuages ou ombres très légères arrivent à échapper à la détection au niveau *L2A*. En général, la moyenne pondérée réduit leur influence, excepté lors de périodes très nuageuses. Comme leur nom l'indique, les synthèses sont produites une fois par mois, mais peuvent être fondées sur des périodes un peu plus longues pour éliminer les derniers résidus et augmenter les chances d'obtenir des observations sans nuages. Les synthèses mensuelles générées se fondent sur ce principe. L'objectif des produits de synthèse mensuelle est de permettre une visualisation et un traitement simple et rapide d'images sans nuages.

Les synthèses mensuelles sont générées par la méthode de la moyenne pondérée à laquelle une correction des effets directionnels est ajoutée, en augmentant progressivement les périodes de synthèses telles que montré dans la Figure 3.18. Au total, cinq périodes de génération de synthèses mensuelles sont utilisées. Afin de comparer les temps de calcul¹⁰ des synthèses mensuelles générées, le Tableau 3.3 montre les dix synthèses mensuelles de séries temporelles sur une période de 45 jours (*P45*) avec les différents nombres d'images Sentinel-2 utilisées dans chaque zone d'intérêt et les temps de génération de leurs synthèses respectives et le Tableau 3.4 présente les synthèses mensuelles de séries temporelles sur les quatre : *P105*, *P165*, *P225*, et *P315* autres périodes de synthèses utilisées.

Les synthèses mensuelles calculent une moyenne pondérée des réflectances de surface pour les observations non nuageuses, issues des produits de niveau *L2A* obtenus avec le logiciel *MAJA*. Cette méthode est très sensible à la qualité du masque des nuages, qui, dans le cas du logiciel *MAJA* n'est pas toujours si bon que cela sur le Cameroun et même très mauvais dans les périodes les plus compliquées (nuageuses). La moyenne pondérée des dates sans nuages utilisées dans la synthèse peut également être fournie avec la moyenne pondérée des réflectances. Cette information est importante parce que ces dates peuvent varier en fonction de la nébulosité des régions à l'heure de passage du satellite. La date moyenne peut varier de 25 jours d'un bout à l'autre d'une région. Négliger cette information conduirait à introduire une erreur maximale de 10 à 15 jours sur la datation de chaque pixel.

En comparant les différentes synthèses, il est possible de constater l'évolution du paysage avec le temps¹¹, ainsi que d'artefacts dus au traitement et au mode d'acquisition de Sentinel-2. Ici, toutes les dates moyennes ont été choisies le 15 de chaque mois afin de passer outre le problème de variation de la date moyenne au cours du mois d'un bout à l'autre d'une région donnée.

10. Les temps de calcul sont obtenus pour un processeur Intel Xeon CPU ES – 2620 / 2.50 GHz × 4, 32 Go. Le facteur de parallélisation de l'ordinateur utilisé est possible grâce aux 24 CPU disponibles.

11. labo.obs-mip.fr/multitemp/14600/

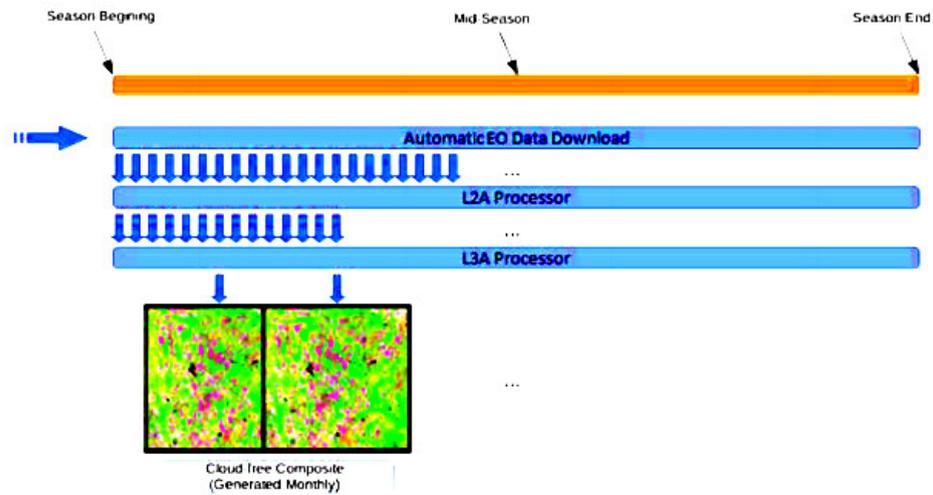


FIG. 3.18 – Processus de génération des synthèses mensuelles de séries temporelles sans nuages d’images Sentinel-2.

TAB. 3.3 – Synthèses mensuelles de séries d’images Sentinel-2 pour une période de 45 jours de l’année 2018 sur les deux zones d’intérêt T33PUL (Z1) et T32NPL (Z2).

Périodes	Synthèses	Nb. images S-2	Temps de calcul
P45	février_P45	14 (Z1)	≈ 9,4 h.
		7 (Z2)	≈ 3,1 h.
	mars_P45	16 (Z1)	≈ 8,6 h.
		4 (Z2)	≈ 2,3 h.
	avril_P45	17 (Z1)	≈ 6,7 h.
		5 (Z2)	≈ 2,8 h.
	mai_P45	16 (Z1)	≈ 8,6 h.
		4 (Z2)	≈ 2,1 h.
	juin_P45	14 (Z1)	≈ 9,4 h.
		7 (Z2)	≈ 2,8 h.
	juillet_P45	17 (Z1)	≈ 6,7 h.
		5 (Z2)	≈ 2,6 h.
	août_P45	14 (Z1)	≈ 9,4 h.
		7 (Z2)	≈ 4,5 h.
	septembre_P45	17 (Z1)	≈ 6,7 h.
		5 (Z2)	≈ 3,8 h.
	octobre_P45	16 (Z1)	≈ 5,7 h.
		6 (Z2)	≈ 4,4 h.
novembre_P45	17 (Z1)	≈ 6,7 h.	
	5 (Z2)	≈ 4 h.	

TAB. 3.4 – Synthèses mensuelles pour des périodes de 105, 165, 225 et 315 jours de l'année 2018 sur les deux zones d'intérêt T33PUL (Z1) et T32NPL (Z2)

Périodes	Synthèses	Nb. images S-2	Temps de calcul
P105	mars_P105	36 (Z1)	≈ 8,6 h.
		14 (Z2)	≈ 6,8 h.
	mai_P105	27 (Z1)	≈ 18,3 h.
		13 (Z2)	≈ 6,5 h.
	juillet_P105	21 (Z1)	≈ 14,4 h.
		10 (Z2)	≈ 5,5 h.
	septembre_P105	27 (Z1)	≈ 38,1 h.
		14 (Z2)	≈ 5,2 h.
novembre_P105	35 (Z1)	≈ 48,1 h.	
	12 (Z2)	≈ 4,9 h.	
P165	avril_P165	48 (Z1)	≈ 54,2 h.
		22 (Z2)	≈ 11,7 h.
	juillet_P165	36 (Z1)	≈ 47,4 h.
		21 (Z2)	≈ 11,3 h.
	octobre_P165	48 (Z1)	≈ 52,1 h.
		22 (Z2)	≈ 11,6 h.
P225	mai_P225	59 (Z1)	≈ 49 h.
		30 (Z2)	≈ 16,1 h.
	septembre_P225	60 (Z1)	≈ 49,7 h.
		30 (Z2)	≈ 15,9 h.
P315	juin_P315	88 (Z1)	≈ 56,1 h.
		38 (Z2)	≈ 17,4 h.

3.2.5 Génération conjointe de MNS photogrammétrique et d'ortho-images

Les ortho-images utilisées ont été élaborées uniquement dans les zones d'intérêt T33PUL et T32NPL avec la chaîne photogrammétrique open source *MICMAC*, acronyme de (*Multi-Images Correspondances, Méthodes Automatiques de Corrélation*), (PIERROT-DESEILLIGNY, 2014) développé à l'IGN, puis au sein du Laboratoire en Sciences et Techniques de l'Information Géographique (*LASTIG*) et décrit à la Section 2.7.2, à partir de Modèles Numériques de Surface (MNS)¹² qui sont utiles pour un grand nombre d'applications - utilisation dans les Systèmes d'Informations Géographiques (*SIG*), production de cartes d'inter-visibilité pour l'optimisation du placement d'antennes pour les télécommunications, cartographie des risques (inondations, glissements de terrain, avalanches, etc.), détection automatique de changements pour la mise à jour des *BDs*, préparation de missions, réalité virtuelle, etc.

Le choix de l'utilisation de *MICMAC* est justifié, outre par sa gratuité et son caractère *open source*, par son haut degré de paramétrisation permettant d'appréhender les prises de vues aériennes acquises par les équipements décrits à la Section 3.2.2. La suite *MICMAC* comprend un ensemble d'outils en ligne de commande. Certains outils sont hautement paramétrables : leur utilisation se fait via l'utilisation de fichiers *XML* regroupant l'ensemble du paramétrage. D'autres outils sont dit simplifiés, par opposition à ces outils complexes. L'utilisation des outils simplifiés se fait au moyen d'une ligne de commande contenant l'ensemble des paramètres.

Pour modéliser la hauteur des objets au sol à partir d'un MNS photogrammétrique, il est nécessaire de disposer d'une information sur l'altitude du vol, qui est fournie par le fichier d'orientation externe avec les prises de vues aériennes effectué en février 2016. L'acquisition a généré des prises de vues

12. Il est également possible de déduire des Modèles Numériques de Terrain (*MNT*) à partir de *MNS* de ces zones d'intérêt.

aériennes à très haute résolution spatiale, de l'ordre de 30 cm. Une première aérotriangulation a été effectuée par le prestataire de service lors des travaux de prises de vues.

3.2.5.1 Calcul des éléments d'orientation du bloc d'images

3.2.5.1.1 Génération des points homologues La génération automatique des points homologues s'effectue au moyen de l'outil *Tapioca* de la suite *MICMAC* interfaçant *SIFT* de (LOWE, 2004). Avec l'outil *Tapioca*, différentes stratégies permettent de calculer les points de liaison. Ces stratégies permettent de déterminer les couples d'images pour lesquels s'effectue le calcul des points homologues. L'approche basique est de sélectionner tous les couples possibles au sein d'un bloc de n images (soit : $n \times (n-1) / 2$ couples d'images), mais cette solution requiert un temps de calcul plus long et n'est pas adaptée à un bloc d'images volumineux. Pour une acquisition par avion avec *GPS* embarqué, l'approche jugée la plus adéquate consiste à sélectionner pour chaque image, toutes les associations de cette image avec ses plus proches images voisines. Pour ce faire, l'outil *OriConvert*, au départ des données d'orientations externes initiales, calcule par triangulation de Delaunay les voisins de chaque image. Le résultat est enregistré sous forme d'un fichier *XML* contenant, pour l'ensemble du bloc d'images, tous les couples résultant. Cette liste de couples d'images est ensuite utilisée par l'outil *Tapioca* pour le calcul des points homologues. Il apparaît inopportun d'effectuer le calcul des points homologues à pleine résolution : les images (de 3648×2736 pixels) sont donc ré-échantillonnées par l'outil *Tapioca* en vue d'obtenir des images d'une largeur de 2000 pixels.

3.2.5.1.2 Calcul de l'orientation absolue finement recalée La détermination des éléments de l'orientation du bloc d'images, à savoir l'orientation externe (position : X, Y, Z et orientation : ω, ϕ, κ) et l'orientation interne (calibration de la caméra), s'effectue au moyen de la méthode de compensation par faisceaux implémentée dans l'outil simplifié *Tapas* (PIERROT-DESEILLIGNY et CLERY, 2011a). La compensation par faisceaux utilise les équations de colinéarité, qui relient les coordonnées images (u, v) des observations de points homologues aux coordonnées modèles (x, y, z), pour résoudre ce système d'équations non-linéaires surabondant. Cette méthode d'ajustement nécessite, outre les observations des points homologues, de disposer d'une valeur initiale des paramètres d'orientation interne. Une calibration initiale de l'appareil photographique est calculée préalablement à l'acquisition avec l'outil *Tapas*. Au cours des travaux, on ne disposait pas de points d'appui. Le calcul de l'orientation relative du bloc d'images, illustré à l'étape (1) du processus de génération de *MNS* à la Figure 3.19, s'effectue ensuite en autocalibration. Le modèle de distorsion utilisé est le modèle de Fraser, utilisant 3 coefficients pour appréhender la distorsion radiale (PIERROT-DESEILLIGNY, 2014).

Le calcul de l'aérotriangulation sans autres observations ou contraintes que celles des points homologues présente un résultat caractérisé par des distorsions non linéaires. L'inspection visuelle du modèle d'aérotriangulation du bloc d'images dans la zone d'intérêt *T32NPL* nous a en effet permis de constater des distorsions paraboliques, créant un effet de bol sur le chantier. L'ajout de contraintes dans la compensation permet de corriger ces distorsions non-linéaires. Nous utilisons pour ce faire les données déjà traitées issues d'un premier calcul d'aérotriangulation (fichier d'orientation externe) dans une nouvelle compensation par faisceaux, opérée avec l'outil *Apero* via l'outil *Campari* (étape (2)). Bien que ces mesures *GPS* soient peu précises et entachées d'un biais dans le sens du vol, biais provoqué par un décalage entre l'enregistrement de la position *GPS* et le moment de la prise de la photographie, la compensation par faisceaux avec les valeurs approximatives des centres optiques des prises de vue permet de supprimer ces distorsions non-linéaires. L'orientation en résultant est

géoréférencée dans un système de coordonnées cohérent avec les données aériennes (dans notre cas, le système de projection WGS84 UTM 32).

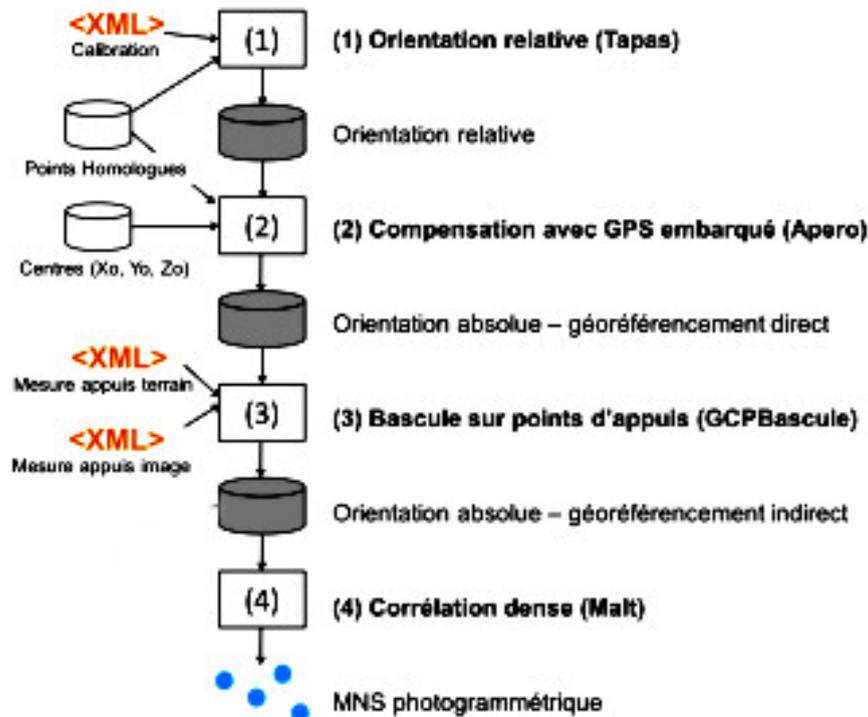


FIG. 3.19 – Processus de génération automatique de MNS photogrammétrique.

L'analyse des résidus sur la position *GPS* des centres dans la compensation à l'étape (2) de la Figure 3.19 nous a permis de constater que l'échelle du modèle est sous-estimée. Afin de mettre le modèle d'aérotriangulation à l'échelle, une bascule sur des points d'appuis est effectuée. La position de six points d'appuis (correspondant à des carrefours et marquages routiers) est relevée sur les images aériennes (mesures notées **Mesure appuis images** dans la Figure 3.19) et leur position sur le terrain (mesures notées **Mesure appuis terrain** dans la Figure 3.19) est déterminée depuis le fichier d'orientation externe. La bascule sur les points d'appuis s'effectue avec l'outil *GCPBascule*, qui détermine la transformation rigide de 7 paramètres (3 translations, 3 rotations et 1 mise à l'échelle du modèle) et permet un géoréférencement d'une précision de l'ordre de 50 cm (résidus des points d'appuis). Ensuite, une corrélation dense avec l'outil simplifié l'outil *Malt* est réalisée en vue de générer un MNS photogrammétrique.

3.2.5.2 Stratégie de corrélation dense et génération d'ortho-images

Les techniques de mise en correspondance automatique d'images se fondent sur un indice de similarité des images, par exemple l'indice de corrélation croisé normalisé, pour apparier ensemble plusieurs vignettes de corrélation aux sein d'une collection d'images.

MICMAC se fonde sur une méthode de corrélation d'images en multi-stéréoscopie et utilise une stratégie multi-résolution (PIERROT-DESEILLIGNY et PAPARODITIS, 2006). Cette approche multi-résolution, qui est à la fois plus rapide et plus robuste, consiste à effectuer successivement l'appariement pour différents niveaux de résolution. La corrélation est effectuée de manière successive sur une pyramide

d'images : à la plus basse résolution, une solution est calculée en explorant un grand intervalle d'incertitude. La géométrie calculée est ensuite utilisée comme solution initiale pour l'appariement à un niveau de résolution supérieur, et ainsi de suite jusqu'à l'obtention d'un modèle très résolu.

La stratégie de corrélation est définie comme étant la séquence hiérarchique de mise en correspondance ainsi que le paramétrage de l'algorithme de corrélation y étant associé. Finalement, l'outil simplifié de mise en correspondance **Malt** avec la stratégie prédéfinie de corrélation **Ortho** dans laquelle pour chaque position (X,Y) dans la géométrie terrain, l'altitude Z est recherchée le long d'un intervalle d'incertitude par la mise en correspondance des vignettes des n -images permettant ainsi le calcul d'un MNS en géométrie terrain (Figure 3.20) ou espace objet (PAPARODITIS, BAGHLI et THOM, 2000), a été utilisé pour générer les ortho-images utilisées sur les deux zones d'intérêt *T33PUL* et *T32NPL*.

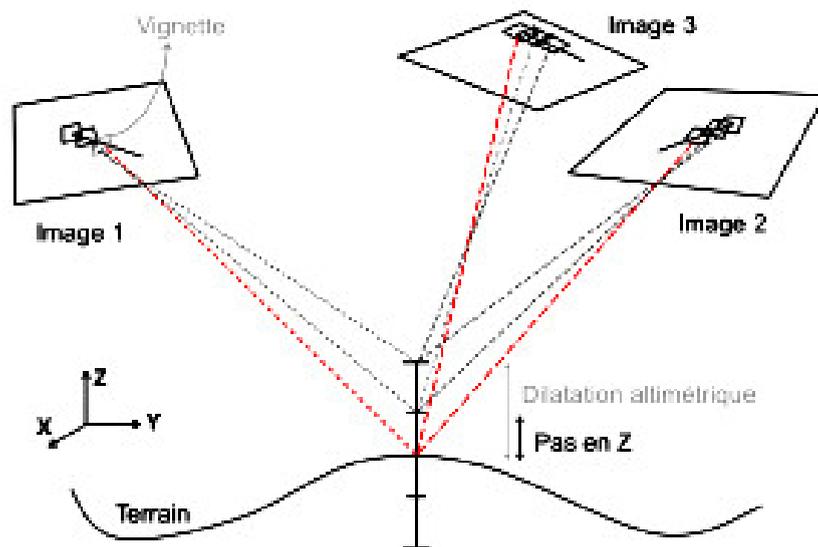


FIG. 3.20 – Corrélation multi-stéréo en géométrie terrain.

3.3 Bases de données cartographiques

3.3.1 Bases de données cartographiques utilisées

La notion de couverture du sol telle que définie dans la Section 1.1.3 doit être bien discernée de celle de l'usage du sol. Cette dernière concerne généralement l'utilisation d'un territoire comme par exemple l'habitat, l'industrie ou encore le commerce. Cependant l'usage du sol nécessite des informations supplémentaires pour être cartographiée et étudiée. En outre, ces deux notions sont très souvent confondues dans les nomenclatures existantes comme par exemple dans *CLC*. Par la suite, nous nous intéresserons uniquement à l'OCS, qui est la seule que l'on peut étudier par télédétection.

Actuellement, la *BD INC* se focalise sur la description d'objets topographiques anthropiques (route, bâtiments etc.), les autres classes d'OCS (e.g. zones naturelles ou agricoles) sont prévues dans la structure de la *BD INC* mais n'ont pas encore été saisies. On a donc besoin d'exploiter des classes provenant d'autres *BDs* afin d'aider (enrichissement et mise à jour) à la production de la *BD INC* se fondant sur le fait que ces classes non saisies ne nécessitent pas une description aussi résolue spatialement. Ainsi, les différentes *BDs* cartographiques utilisées sont décrites par la suite.

3.3.1.1 Base de données de l'INC (BD INC)

La *BD INC* est une *BDs* géographique vectorielle qui a pour but, d'abord et avant tout, de donner à tous les usagers une référence géométrique de précision métrique, sur l'ensemble du territoire. A ce titre, elle sert de socle à la représentation cartographique à l'échelle 1/25000.

Pour cela, elle comprend un ensemble de données issues de mesures photogrammétriques précises et pour lesquelles on cherche la meilleure exhaustivité possible. Il s'agit de l'ensemble du : 1) réseau des routes revêtues ou non, et des pistes, 2) réseau ferroviaire, 3) réseau électrique à haute et très haute tension et 4) réseau hydrographique dont la continuité est assurée au mieux sauf en zones plates. L'ensemble de ces informations constitue le socle de la *BD INC* et assure la continuité et la cohérence avec les données existantes et à venir.

Ces informations sont complétées par des données topographiques, également issues de mesures photogrammétriques, dont la précision géométrique peut être différente et dont l'exhaustivité ne peut être aujourd'hui assurée mais qui sont des éléments intéressants pour la description du paysage et le repérage des lieux. Il s'agit : 1) de l'**ensemble du bâti** mais seuls les bâtiments les plus importants sont représentés à l'échelle, 2) de la **description** de l'OCS, 3) d'une **sélection** des principaux sentiers, 4) de nombreux **attributs sémantiques** qui ne visent pas à une description thématique exhaustive mais permettent un meilleur repérage et une meilleure appréciation de la diversité de la géographie décrite, 5) des **toponymes** qui sont attachés aux objets linéaires quand il y a lieu ou sont positionnés de façon indicative pour les autres cas et 6) des **limites administratives** représentatives même si une précision géométrique quasi métrique ne peut être garantie aujourd'hui.

Par ailleurs, le relief est décrit sous forme de Modèles Numériques de Terrain et de courbes de niveaux déterminés à partir des éléments orographiques et hydrographiques issus des mesures photogrammétriques. En outre, la *BD INC* comprend des éléments d'altimétrie concernant certaines classes d'objets et des éléments artificiels du relief susceptibles d'être utilisés pour générer des ortho-images. La *BD INC* est conçue en tant que référentiel permettant l'agrégation d'autres données plus thématiques notamment issues de l'exploitation des ortho-images devant répondre à une large diversité de besoins. Dans le cadre de mises à jour futures, la qualité et le contenu des informations pourront évoluer en fonction des besoins exprimés ou des enrichissements proposés par des partenaires.

3.3.1.1.1 Spécifications générales de contenu

Extension géographique et partition La *BD INC*, toutes versions confondues, couvrira toute l'étendue du territoire national camerounais.

Extension géographique

La règle de débordement de la *BD INC* est fixée à 500 m maximum au delà des frontières. Les données en territoire étranger font partie intégrante des lots *BD INC*. En mer, l'extension de la *BD INC* correspond à celle des feuilles dont la description figure ci-dessous.

Description du découpage

La production de la *BD INC* est gérée au fur et à mesure de la disponibilité des prises de vues numériques d'images aériennes nécessaires aux mesures photogrammétriques. Les découpages sont préparés en feuilles au 1/25 000.

Gestion des raccords

Les règles de raccord sont les mêmes entre couples, entre dalles ou entre feuilles à savoir : 1) les raccords sont **parfaits** à 100 % pour les mêmes année et saison de prises de vues aériennes ainsi que la même année de saisie photogrammétrique et 2) les raccords sont **meilleurs** mais seules des évolutions du paysage, des changements de spécifications ou une erreur dans la saisie la plus ancienne justifient un mauvais raccord pour les années et/ou saisons différentes des prises de vues aériennes.

Références géodésiques En production, le système de référence est *WGS84*, associé à la projection *Universal Transverse Mercator (UTM)*. L'altimétrie étant sur le modèle de géoïde associé au *RGC*.

Description géométrique et topologique Tous les objets simples sont représentés par des points, des lignes ou des surfaces selon la classe et la structure topologique est élémentaire.

Localisation

Tous les objets simples sont localisés par des **points**, des **lignes** ou des **surfaces** qui peuvent être définis par des coordonnées bidimensionnelles ou tridimensionnelles selon la classe de manière que l'objet est décrit par un point unique dans une localisation ponctuelle, une ligne simple unique dans une localisation linéaire, une surface unique, éventuellement trouée dans une localisation surfacique et une ou plusieurs surfaces disjointes dans une localisation multi-surfacique.

En restitution photogrammétrique, tous les objets sont saisis en trois dimensions à l'exception de certains objets surfaciques.

Structure topologique des différents domaines d'information

La structure topologique finale de la *BD INC* ne concerne pas directement la phase de restitution qui s'attachera à modéliser la réalité telle qu'elle est vue sur les photographies tout en respectant une structure topologique élémentaire.

3.3.1.1.2 Spécifications générales de qualité

Qualité géométrique Dans la *BD INC*, la notion de qualité géométrique est intimement liée à la source des données, spécifiée dans un attribut spécifique commun à toutes les classes.

Pour les objets saisis par voie photogrammétrique à l'échelle *1/10000* et contrôlés par la même voie, le coefficient de qualité est fixé à $C = 1$, pour une incertitude de mesure moyenne (*EMQ*) attendue de *0,80 m*, impliquant une limite maximale d'acceptation de *2,15 m* pour *X* ou *Y* en zone plate et en supposant une qualité d'aérotriangulation de *20 cm*. Dans les mêmes conditions, l'*EMQ* en altimétrie attendue est de *1,75 m* impliquant une tolérance maximale de *4,67 m* pour *Z* en zone plate.

S'il s'avérait indispensable de disposer d'une meilleure qualité géométrique, il suffirait de lever des points *Ground Control Point (GCP)* supplémentaires dans la zone concernée puis de recalculer une aérotriangulation et d'utiliser un cliché sur deux pour la restitution photogrammétrique.

Qualité sémantique (exhaustivité, confusions) En terme d'exhaustivité (excédents et déficits) et en terme de confusions entre classes, elle fait l'objet de contrôles a posteriori.

Exhaustivité

Pour les classes et les attributs de la *BD INC*, on distingue :

- d'une part ceux pour lesquels il y a des exigences de résultat définissant la conformité aux spécifications ;
- d'autre part ceux pour lesquels les objectifs sont de donner une information lorsque cela est possible. La qualité de ces informations pourra s'enrichir au cours de la vie de la *BD INC*, en particulier lors des mises à jour de celle-ci.

Exigences d'exhaustivité : 1) réseau routier et pistes (au moins 98 %), 2) réseau ferré (au moins 99 %), 3) réseau électrique haute tension (*HT*) (au moins 95 %), 4) hydrographie permanente (au moins 99 %, sauf en zone boisée couverte), 5) hydrographie temporaire (au moins 90 %), 6) bâti (95 % pour le bâti individuel et 98 % pour les autres bâtiments), 7) pistes d'aérodrome (99 %), 8) réservoirs (90 %) et 9) points d'eau (98 %).

Objectifs d'information conditionnelle : 1) les sentiers (une sélection des plus importants est réalisée à la saisie), 2) les transports par câble, 3) les canalisations (la continuité du réseau n'est pas toujours assurée), 3) les cimetières et 4) les lignes orographiques (exhaustivité variable selon le couvert végétal).

Le processus de contrôle à la saisie puis de **mise à jour en continu** permettra une **amélioration progressive** de la qualité sémantique de la *BD INC*.

Source des attributs Les données attributaires proviennent de différentes sources. Pour une classe donnée, les sources de l'information sémantique et celles de l'information géométrique ne coïncident pas forcément.

3.3.1.2 Produits et base de données *GLC (BD GLC)*

La couverture du sol est définie comme le matériau biophysique à la surface de la Terre et sous-surfaces immédiates, y compris, entre autres, l'herbe, les arbustes, les forêts, les terres cultivées, les terres stériles, les plans d'eau (y compris les eaux souterraines) et les structures artificielles (MEYER et TURNER, 1994; LAMBIN et GEIST, 2010; GIRI, 2012). Le changement d'OCS est le passage d'un type d'OCS à une autre ou/et la modification d'une zone au sein d'une OCS (MEYER et TURNER, 1994). Le changement d'OCS entraîne des changements environnementaux importants aux échelles locale, régionale et mondiale. Par exemple, la transition des forêts vers des terres agricoles ou l'expansion urbaine vers des cultures affecte la biodiversité, la qualité des sols, le climat et la santé humaine (LAMBIN et GEIST, 2010; FEDDEMA et al., 2005; DEFRIES, ASNER et HOUGHTON, 2004).

La compréhension et le suivi de la distribution et des dynamiques de l'OCS sont des facteurs importants dans les études environnementales. Une information à jour sur l'OCS est essentielle pour les organisations gouvernementales, non-gouvernementales et autres parties prenantes aidant au développement et à la mise en oeuvre de politiques environnementales pour un avenir durable (GREKOUSIS et MOUNTRAKIS, 2015; YAN, SHAKER et ASHMAWY, 2015; GIRI, 2012; FERANEC et al., 2007). Les activités humaines liées à la satisfaction de besoins sociétaux et individuels spécifiques sont les principaux moteurs de la dynamique de l'OCS contemporaine (GREKOUSIS, KAVOURAS et MOUNTRAKIS, 2015; TURNER, L.II 2006; JARNAGIN, 2004). En effet, les humains ont affecté la terre (principalement pour la production alimentaire) pendant des milliers d'années. L'ampleur du changement d'OCS et les modifications relatives vont grandissantes (ELLIS et PONTIUS, 2007). Contraindre les implications négatives du changement d'OCS tout en maintenant la production des ressources essentielles est actuellement une préoccupation majeure pour la communauté scientifique et les décideurs du monde entier (ELLIS et PONTIUS, 2007).

Pour estimer l'étendue des dynamiques de l'OCS et évaluer leurs implications environnementales, il existe divers ensembles de données d'OCS régionales et mondiales (*Global Land Cover (GLC)*). De nombreuses institutions, des organisations et des agences composées de scientifiques et de décideurs, analysent et utilisent des données et des produits variés d'OCS régionaux et mondiaux et fournissent des suggestions politiques, afin de s'arrimer aux visions de développement durable. Un exemple est la conférence Rio+20 (ONU, 2012a) avec un rapport produit qui indique clairement l'importance de la cartographie de l'OCS à l'échelle mondiale pour parvenir à un développement durable à travers des études scientifiques et des initiatives qui aideront à la gestion durable des politiques et des pratiques en matière d'OCS (ONU, 2012b). Les produits d'OCS représentent les systèmes d'appui aidant à l'application des objectifs des décideurs et des politiques. Pour cette raison, il est essentiel que les produits d'OCS soient les plus précis et fiables possibles afin que leur utilisation soit sûre et cohérente. Et pourtant, en réalité, en raison des grandes différences dans les approches méthodologiques de chaque produit *e.g.* schémas et techniques de classification, temps d'acquisition des données, résolution spatiale, il y a souvent un mauvais accord entre les différents ensembles de données lorsqu'ils sont appliqués au niveau régional ou mondial (GONG et al., 2013; HEROLD et al., 2008). Les incohérences, les incertitudes et les imprécisions sus-mentionnées rendent problématiques l'utilisation des produits d'OCS, car il est difficile à plusieurs utilisateurs de se servir efficacement de ces ensembles de données pour diverses applications (TSENDBAZAR, BRUIN et HEROLD, 2015; CONGALTON et al., 2014). De plus, la plupart des produits courant de *GLC* décrivent les distributions spatiales de divers types d'OCS, mais ils n'évaluent pas les processus et les changements d'OCS (ZHANG et al., 2014). L'analyse de la détection des changements n'est pas indépendante de la sources de données originales et leur exactitude associée et, par conséquent, il est d'une importance cruciale de sélectionner avec soin les ensembles de données associés.

Avec l'avènement de la technologie et la baisse constante du coût des données satellitaires, divers produits d'OCS régionaux et mondiaux ont été créés et d'autres devraient être opérationnels dans un avenir proche. Avec la prolifération des produits de télédétection et les améliorations de la variabilité, de l'accessibilité et du coût, les produits d'OCS sont devenus des entrées essentielles pour les études interdisciplinaires, par exemple liées au climat et aux dynamiques de séquestration du carbone. Et pourtant, en raison de la pléthore de produits d'OCS existants, avec différentes spécifications obtenues et précisions atteintes, la question du choix des produits adaptés en fonction des besoins de différents utilisateurs est cruciale. Plusieurs revues offrent une analyse descriptive comparative et approfondie. Par exemple, (CONGALTON et al., 2014) ont effectué un examen et une analyse des incertitudes dans les produits d'OCS largement utilisés suivants : programme international pour la géosphère et la biosphère (*International Geosphere-Biosphere Program (IGBP)*), Université du Maryland (*University of Maryland (UMD)*), OCS mondiale (*Global Land Cover 2000 (GLC 2000)*), et *GlobCover 2009*. (MORA et al., 2014) ont résumé les caractéristiques de sept produits d'OCS : 1) *IGBP DISCover*, 2) *UMD*, 3) *Moderate Resolution Imaging Spectroradiometer (MODIS) 500 m*, 4) *GLC 2000*, 5) *Global Land Cover by National Mapping Organizations (GLCMNO)*, 6) *GlobCover*, et 7) *GlobCover version 2*. (HEROLD et al., 2008) ont analysé l'analogie et la précision de quatre produits de *GLC* à 1 km de résolution spatiale : 1) *IGBP DISCover*, 2) *UMD*, 3) *MODIS 1 km* et 4) *GLC 2000*. (JUNG et al., 2006) ont mis en évidence les forces et les faiblesses des caractéristiques de *GLC (Global Land Cover Characteristics (GLCC))*, de *GLC 2000* et de *MODIS*. Au niveau régional, (BAI et al., 2014) ont testé la fiabilité de cinq produits de *GLC* en Chine :

1) *GLCC*, 2) *UMD*, 3) *MODIS*, 4) *GLC 2000*, et 5) *GlobCover*) et (TCHUENTE, ROUJEAN et JONG, 2011) ont effectué une évaluation de la qualité des produits : *GLC 2000*, *GlobCover* et *MODIS* pour l'Afrique.

Cet état-de-l'art des produits de *GLC* fournit des informations importantes et laisse entrevoir des suggestions précieuses. Pour exemple, des conclusions ont été tirées en ramenant les différents produits à la même résolution spatiale ou en agrégeant leurs systèmes de classification dans une légende unifiée. En raison du grand volume, les revues existantes se concentrent sur un nombre limité de produits d'OCS. Et pourtant, des études restent à faire sur l'étude des caractéristiques, des limites et des perspectives de même que des leçons demeurent à apprendre à partir non seulement de l'étude de certains produits spécifiques d'OCS, mais également sur la majorité des produits d'OCS régionaux et mondiaux. S'appuyant sur les efforts existants et motivés par la grande importance de ces ensembles de données d'OCS, notre objectif consiste à : 1) résumer les caractéristiques et la méthodologie de production de la majorité des produits d'OCS régionaux et mondiaux, et 2) proposer des stratégies de production de cartes d'OCS.

3.3.1.2.1 Approches existantes et leurs inconvénients Dans cette section, nous donnons un aperçu des produits d'OCS existants et des approches utilisées pour leur production. Pour un examen approfondi des produits existants, le lecteur peut se référer à (GREKOUSIS, MOUNTRAKIS et KAVOURAS, 2015) parmi lesquels nous avons sélectionné des produits similaires à ceux que nous proposons en terme de résolution.

Produits mondiaux *FROM-GLC* (GONG et al., 2013), est la première carte d'OCS mondiale produite à une résolution spatiale de 30 m. Elle comporte 9 classes d'OCS et sa précision est estimée à 63,7 %. Elle a été produite à partir d'images s'étalant sur plus de 20 années, ce qui rend difficile la compréhension de la signification des classes sélectionnées. Par exemple, les prairies pâturées avec des traces de culture sont répertoriées dans les terres stériles en raison de leur fonction d'OCS. Elle a nécessité un nombre très faible d'échantillons (90 000 pour l'entraînement et 39 000 pour la validation), qui ont été sélectionnés par photo-interprétation sur *Google Earth*. Seules les images de la saison de croissance ont été utilisées. L'entraînement a été effectué scène par scène, en mettant en commun un certain nombre de scènes voisines lorsque quelques échantillons seulement étaient disponibles.

FROM-GLC-seg (SMITH et MARTINEZ, 2015) est une version améliorée de la précédente, utilisant *MODIS* pour introduire des fonctionnalités temporelles, mais toujours avec les problèmes liés à l'utilisation d'une période pluriannuelle. La précision est supérieure (64,4 %), mais le coût et la faisabilité présentent les mêmes inconvénients. La troisième version du *FROM-GLC* est appelée *FROM-GLC-agg* (YU et al., 2014), et consiste en une agrégation de la précédente à une résolution plus grossière afin de réduire les erreurs et la précision estimée est de 65,5 %.

Enfin, (CHEN et al., 2015a) ont produit de manière similaire une carte d'OCS, mais en combinant des approches basées sur les pixels et sur les objets. Comme les produits précédents, celle-ci est fondée sur une classification supervisée à partir d'échantillons obtenus par photo-interprétation. La résolution spatiale de 30 m de la carte est obtenue à l'aide d'images Landsat et *HJ-1*, mais pas par une approche multi-temporelle. Les informations temporelles nécessaires à la caractérisation de la végétation sont obtenues en utilisant les données *MODIS NDVI*, mais cela a l'inconvénient d'abaisser la résolution spatiale effective du produit final à 250 m. La stratégie de classification utilise une combinaison complexe de différents classifieurs dont certains implémentent des règles de décision selon des experts

et qui sont spécifiques aux classes et aux paysages. Par exemple, on peut considérer l'expression selon laquelle « les objets obtenus par segmentation ont été superposés sur des images potentielles de terres cultivées. Seuls les objets affichant des motifs artificiels réguliers tels que des cercles ou des rectangles et pour lesquels la proportion de pixels potentiels de terres cultivées dans l'objet était supérieure à un seuil prédéfini *i.e.* 70 % ont été identifiés comme des terres cultivées par interprétation visuelle ». Ce type d'approche peut introduire un manque de généralisation et ne fonctionnera certainement pas sur de nombreux systèmes de culture dans le monde.

Cependant, malgré les inconvénients et les limites des produits mentionnés ci-dessus, ces auteurs ont montré la faisabilité de la production de cartes d'OCS mondiale à haute résolution spatiale.

Produits continentaux et nationaux Les produits continentaux ont les mêmes difficultés que les produits mondiaux, dans le sens où des volumes de données et une variabilité à travers les paysages sont déjà présents. (GIRI, 2012) ont produit une carte d'OCS pour l'Amérique du Sud pour l'année de référence 2010 en utilisant l'imagerie Landsat à 30 m de résolution spatiale. La carte ne fournissait que 5 classes (arbres, eau libre, dénudée, neige/glace pérenne et autre végétation) et la précision estimée était de 89 %. L'approche était fondée sur une classification supervisée sur une mosaïque d'images de la saison de croissance, ce qui ne permet pas de prendre en compte les informations phénologiques. Comme pour les produits présentés ci-dessus, la photo-interprétation a été utilisée pour la sélection des échantillons d'apprentissage. L'approche était itérative en ajoutant des échantillons dans les zones où les résultats n'étaient pas satisfaisants, suivi d'une re-classification manuelle des « pixels apparents mal classés ». Comme on peut le voir, cette approche est loin d'être automatique et ne s'adapte donc pas aux mises à jour fréquentes (sauf si on re-apprend à partir du produit existant).

Les cartes d'OCS au niveau national présentent moins de difficultés que les cartes aux niveaux continental ou mondial. Par exemple, la collecte de données de référence peut être plus facile et la variabilité du paysage est plus faible. Un exemple de ce type d'approche est la BDs nationale américaine sur l'OCS (HOMER et al., 2007), qui est une carte à 30 m de résolution avec 16 classes et une précision globale estimée à 80 %, bien que la carte de 2001 n'avait pas encore été officiellement validée en 2007. La production de la carte avait nécessité 12 équipes de cartographie du gouvernement et du secteur privé et le traitement avait été effectué par saisie manuelle. Il est important de noter que la mise à jour de ce produit a été effectuée par détection de changement (JIN et al., 2013), réduisant ainsi la quantité de travail. Cependant, cette approche nécessite une connaissance préalable des trajectoires susceptibles d'être prises par les différentes classes OCS. Des approches similaires ont été mises en oeuvre en Chine (DENG et LIU, CRC Press : Boca Raton, FL, USA, 2012; ZHANG et al., 2014) et présentent les mêmes inconvénients et limitations liés à la dépendance aux données d'entrée.

3.3.1.2.2 Produit d'OCS en Afrique AFRICOVER est un projet visant à fournir des informations précises sur les différents OCS pour l'ensemble du continent africain (JUNG et al., 2006). Pourtant, actuellement seule l'Afrique de l'Est (12 pays participants) a un produit fini. Chaque pays développe son propre produit d'OCS sur la base de spécifications communes visant à atteindre une précision globale supérieure à 80 %.

En Afrique, la carte du projet *Global Land Cover 2000 (GLC 2000)* fait partie de la cartographie mondiale de l'OCS (*GLC 2000*) et de la cartographie des surfaces brûlées (*GBA 2000*) pour l'an 2000 à partir de données SPOT VEGETATION. Ce projet est organisé et conduit par le Centre Commun de

Recherche (Unité de Surveillance Mondiale de la Végétation, Institut pour l'Environnement Durable), en partenariat avec de très nombreuses institutions européennes et non-européennes. Plusieurs cartes régionales ont été produites, et ensuite rassemblées au niveau mondial après un processus d'harmonisation des légendes. Une vue générale du projet est disponible dans (BARTHOLOMÉ et al., 2002) et (GRÉGOIRE, TANSEY et SILVA, 2003).

Présentation de la carte du projet GLC 2000 La nouvelle carte permet de contrôler les grandes évolutions d'OCS qui se sont produites au cours des dix dernières années. Cette carte est nécessaire pour baser des études plus fines et pour diriger des programmes de recherche, d'aide et de développement. Toutefois, la résolution spatiale de l'image satellite n'est pas appropriée pour détecter de petites ouvertures dans la couverture forestière ou l'exploitation sélective du bois.

Premières cartes d'OCS en Afrique Plusieurs études cartographiques continentales ont été déjà entreprises : les premières ont été basées sur la compilation des cartes nationales et locales enrichies par la consultation de nombreux experts (WHITE, 1983; SAYER, HARCOURT et COLLINS, 1992; OLSON et al., 2001). À la fin des années 1980 le Programme IGBP avait exprimé un besoin pour des cartes mondiales d'OCS afin de soutenir la recherche sur le changement global. (LOVELAND et al., 1999) ont publié la carte d'OCS IGBP basée sur les données AVHRR de l'année 1992 de résolution spatiale de 1 km. Ce produit a été largement utilisé dans la recherche sur le changement global et pour soutenir les travaux d'autres groupes tels que les organisations non-gouvernementales de conservation et les programmes d'aide au développement. Toutefois, ces derniers ont montré la nécessité de disposer d'un produit aux meilleurs détails spatial et thématique, adapté aux échelles régionales ou continentales.

TAB. 3.5 – Premières cartes d'OCS en Afrique.

Titre	Auteur	Date	Méthodes
Zones biotiques	HOLDRIDGE	1971	Stratification bioclimatique
Végétation de l'Afrique	WHITE	1983	Consultation d'experts et compilation d'informations locales
Atlas de conservation des forêts tropicales	SAYER et al.	1992	Compilation des cartes forestières nationales
Caractérisation globale de l'OCS	LOVELAND et al.	1999	Analyse par satellite
Classification globale de l'OCS	HANSEN et al.	2000	Analyse par satellite
Zones écologiques globales	FAO	2000	Agrégation des cartes régionales
Écosystèmes terrestres (WWF)	OLSON et al.	2001	Consultation d'experts et compilation d'informations locales

Applications des premières cartes d'OCS en Afrique La résolution spatiale de 1 km de la carte ne permet pas la détermination précise des changements d'OCS. Pour beaucoup de classes d'OCS, la fragmentation spatiale conduit à une surestimation ou une sous estimation des surfaces. En Afrique, il y a un problème spécifique avec les zones agricoles qui sont mélangées souvent aux savanes naturelles d'où le problème lié à la résolution d'1 km (i.e. à partir de quel stade passe-t-on d'une catégorie à une autre?). Néanmoins, pour la majeure partie du continent, cette résolution rend compte de la dimension moyenne des communautés de végétation.

La précision thématique de telles cartes est élevée aux niveaux agrégés. Ainsi, dégrader la classification au niveau des forêts, savanes boisées et des savanes herbues aboutit à une précision plus élevée de la carte qu'en maintenant les classes détaillées.

D'autre part, les comparaisons avec les cartes précédentes ne peuvent se faire qu'au niveau qualitatif. Il serait excessivement présomptueux d'essayer de mesurer le changement d'OCS entre la carte actuelle et la carte précédente de TREES. Une approche appropriée pour cet exercice serait d'utiliser les changements perçus entre ces cartes pour une stratification et l'utilisation de données spatiales à plus fine résolution au sein des strates montrant des changements (ACHARD et al., 2006).

3.3.1.3 Base de données OSM (BD OSM)

OpenStreetMap (OSM) est le projet d'information géographique participatif le plus réussi à ce jour (FOODY et al., 2017). Il a été lancé en 2004 en réponse à la présence généralisée de restrictions légales ou techniques sur les cartes disponibles, dans le but ultime de créer et de distribuer des données géographiques gratuites pour le monde entier¹³. En fait, la BDs géospatiales OSM est distribuée sous la licence *Open Access Open Database License (ODbL)*¹⁴, permettant librement d'utiliser, de modifier et de développer la BDs dans des conditions non restrictives telles que la fourniture d'attribution aux contributeurs OSM. Le moyen relativement facile - même pour les personnes sans formation en géographie ou en informatique - de créer des données OSM a jusqu'à présent attiré un nombre toujours croissant de contributeurs au projet. En juin 2019, le projet comptait environ 5,5 millions d'utilisateurs enregistrés¹⁵, alors que le nombre de contributeurs, c'est-à-dire les utilisateurs ayant apporté au moins une modification à la BDs, a dépassé le seuil de 1 million seulement en mars 2018¹⁶. À son tour, un riche écosystème d'outils logiciels, de services et d'applications permet à un grand nombre de développeurs, d'opérateurs humanitaires, d'acteurs industriels et gouvernementaux d'exploiter les données OSM au quotidien et à des fins diverses (MOONEY et MINGHINI, 2017).

En tant que source potentiellement utile d'informations géospatiales pour de nombreuses disciplines, OSM a également suscité un intérêt croissant de la part de la communauté académique et scientifique (JOKAR et al., 2015b). Sans surprise, le sujet qui a jusqu'à présent été le plus étudié par les chercheurs est l'évaluation de la qualité d'OSM (SEHRA, SINGH et RAI, 2017a), puisque l'information géographique souffre par définition d'un manque général d'assurance qualité (GOODCHILD et LI, 2012). La qualité d'OSM a traditionnellement été évaluée à l'aide des paramètres de qualité standard disponibles pour les ensembles de données géospatiales, par exemple la précision de la position, l'exhaustivité, la cohérence logique, la précision thématique, la précision temporelle, la lignée, l'actualité et l'aptitude à l'emploi¹⁷ (GOODCHILD et LI, 2012; VEREGIN, 1999; DEVILLERS et JEANSOULIN, 2010). Ce dernier suggère que la qualité ne doit pas être mesurée en termes absolus, car les ensembles de données participatives tels que OSM peuvent avoir différents degrés d'adéquation à des fins spécifiques et aux demandes des utilisateurs.

Dans le cas d'OSM, ces paramètres de qualité ont été traditionnellement mesurés par des approches de qualité extrinsèques, c'est-à-dire en comparant OSM à des ensembles de données de référence

13. https://wiki.openstreetmap.org/w/index.php?title=Main_Page&oldid=1060762.

14. <https://opendatacommons.org/licenses/odbl/1.0/index.html>.

15. https://www.openstreetmap.org/stats/data_stats.html.

16. <https://blog.openstreetmap.org/2018/03/18/1-million-map-contributors>.

17. http://www.iso.org/iso/home/store/catalogue_ics/catalogue_detail_ics.htm?csnumber=32575.

externes considérés comme la vérité terrain (*VT*), tels que ceux fournis par les agences nationales de cartographie et les sociétés de cartographie commerciales. Les paramètres de qualité qui ont été le plus investigués par des approches extrinsèques sont la précision de positionnement, la complétude et la précision thématique, l'accent étant principalement mis - par ordre décroissant - sur les routes d'*OSM* (HAKLAY, 2010; CANAVOSIO-ZUZELSKI, AGOURIS et DOUCETTE, 2013; GRASER, STRAUB et DRAGASCHNIG, 2015; BROVELLI et al., 2017; BARRINGTON-LEIGH et MILLARD-BALL, 2017), les bâtiments (HECHT, KUNZE et HAHMANN, 2013; FAN et al., 2014; FRAM, CHISTOPOULOU et ELLUL, 2015; BROVELLI et al., 2016), l'*OCS* (ESTIMA et PAINHO, 2015; JOKAR et al., 2015c; FONTE et al., 2017) et points d'intérêt (GIRRES et TOUYA, 2010; JACKSON et al., 2013). Dans l'ensemble, la littérature disponible s'accorde à dire que la qualité d'*OSM* montre des modèles très hétérogènes dans l'espace, allant des zones où elle se compare favorablement aux ensembles de données faisant autorité (généralement les zones les plus urbanisées) aux zones où les données sont manquantes ou de mauvaise qualité.

Cependant, *OSM* et les ensembles de données faisant autorité sont extrêmement différents par nature, par exemple en termes de processus de production et de mise à jour qui conduisent souvent *OSM* à être clairement localement plus détaillé, précis et complet que les ensembles de données faisant autorité, violant ainsi l'hypothèse de base de l'utilisation de ces derniers comme *VT* (ANTONIOU et SKOPELITI, 2015). En outre, dans de nombreuses régions du monde, des ensembles de données faisant autorité sont soit manquants, soit inadaptés à la comparaison (par exemple parce que leur échelle est trop grossière et non comparable à *OSM*). Pour ces raisons, les méthodes d'évaluation intrinsèque d'*OSM* ont commencé à apparaître dans le but de déterminer la qualité d'*OSM* (principalement en tant qu'aptitude à l'emploi) en ne regardant que l'évolution temporelle de l'*OSM* lui-même, c'est-à-dire sans comparaison avec des ensembles de données tiers. Étant donné que chaque modification de la *BDs* est également stockée avec la *BDs* elle-même, toute l'historique d'*OSM* est en fait disponible et fournit une source de données extrêmement riche à diverses fins, y compris l'évaluation de la qualité. En conséquence, de nombreuses implémentations logicielles ont été développées, basées sur l'analyse de l'historique d'*OSM*.

La *BDs OSM* a été étudiée par de nombreux chercheurs pour atteindre un certain nombre d'objectifs. L'évaluation de la qualité est de loin la plus fréquente. (CIEPLUCH, MOONEY et WINSTANLEY, 2011) a développé un ensemble d'indicateurs de qualité pour *OSM* qui a également pris en compte l'historique et le profil des contributeurs. De même, les méthodes intrinsèques développées par (KESSLER et GROOT, 2013) et (MUTTAQIEN, OSTERMANN et LEMMENS, 2013) ont modélisé la qualité des objets d'*OSM* sur la base d'informations historiques telles que le nombre de contributeurs et le nombre de versions. L'historique des objets et des contributeurs d'*OSM* a été exploité par (MOONEY et CORCORAN, 2014) pour analyser les modèles de contributeurs dans sept villes du monde. (GRÖCHENIG, BRUNAUER et REHRL, 2014) ont développé une approche intrinsèque pour l'évaluation de l'exhaustivité d'*OSM* à travers l'analyse des contributions de la communauté au fil du temps. Une nouvelle approche pour améliorer la précision de la position et l'exhaustivité du réseau routier d'*OSM* à l'aide de l'historique d'*OSM* a été proposée par (NASIRI et al., 2018). (BARRON, NEIS et ZIPF, 2014) a développé un cadre complet pour l'évaluation de la qualité intrinsèque d'*OSM*, qui comprend plus de 25 méthodes et indicateurs exclusivement basés sur l'historique d'*OSM*.

La disponibilité de l'historique d'*OSM* a également été exploitée pour l'analyse intrinsèque de l'évolution temporelle d'objets *OSM* spécifiques. Par exemple, la croissance du réseau routier d'*OSM* a été analysée pour des pays comme l'Irlande (CORCORAN, MOONEY et BERTOLOTTO, 2013) et

l'Allemagne (NEIS et al., 2011), et des villes comme Pékin (ZHAO et al., 2015) et Ankara (HACAR, KILIÇ et ŞAHBAZ, 2015). (BARRINGTON-LEIGH et MILLARD-BALL, 2017) ont évalué la complétude du réseau routier d'OSM au niveau mondial - trouvant une valeur d'environ 83 % - en étudiant également sa croissance historique. Un travail récent de (TIAN, ZHOU et FU, 2019) ont analysé l'évolution de 2012 à 2017 des bâtiments d'OSM en Chine. (JOKAR et al., 2015a) ont modélisé l'évolution d'OSM à Heidelberg à travers une analyse spatio-temporelle des contributions d'OSM, tandis que (MINGHINI, BROVELLI et FRASSINELLI, 2018) ont effectué une analyse intrinsèque de l'évolution des noeuds d'OSM à Dar es Salaam, mettant en évidence des schémas spatio-temporels clairs induits par un projet de cartographie communautaire. En utilisant des indicateurs de qualité intrinsèque basés sur l'historique d'OSM, (SEHRA, SINGH et RAI, 2017b) ont évalué l'évolution d'OSM en Inde. Les informations historiques d'OSM ont également été utilisées pour caractériser la réponse des contributeurs à la suite de catastrophes naturelles, par exemple en termes de fréquence des mises à jour et de types de contributeurs (utilisateurs novices ou expérimentés d'OSM) (DITTUS, QUATTRONE et CAPRA, 2017; MINGHINI et al., 2017; AUER et al., 2018).

3.3.2 Définition et choix d'une nomenclature

La nomenclature d'une carte d'OCS est à la base de la production de cette carte. Il s'agit en effet d'identifier les différents types de surfaces présents dans une zone d'étude donnée, d'intérêt significatif pour l'utilisation de la carte produite sur cette zone d'étude, mais aussi potentiellement distinguables des autres types de surfaces à partir du jeu de données de télédétection disponibles. La chaîne de traitement (*iota*² dans notre cas) s'applique ensuite à affecter, à chaque pixel de l'image, un type et un seul dans cette nomenclature. Si celle-ci est mal définie (classes ambiguës thématiquement, ou classes indissociables d'un point de vue numérique, par exemple), les cartes d'OCS produites seront peu robustes et peu fiables pour répondre à cette nomenclature. Il est donc généralement préférable de limiter le nombre de classes, en regroupant notamment des classes thématiques différentes mais sémantiquement proches et dont la différenciation se fonde sur un niveau d'information inaccessible au vu des capacités intrinsèques à la donnée de télédétection disponible.

Une première proposition de nomenclature des types d'OCS, orientée vers la cartographie du Cameroun, avait été faite par l'INC au cours de l'année 2015 (confère Tableau A.12). Une nomenclature directement analogue à celle de la *BD INC* ne peut pas être établie car les classes de celle-ci ne sont pas séparables/reconnaissables uniquement à partir de données Sentinel-2.

Nous avons donc procédé à la définition d'une nomenclature plus abordable, dans le but de parvenir progressivement à une nomenclature ayant le niveau de détails plus approprié à la méthodologie de classification qui sera adoptée. En particulier pour les expériences réalisées, nous avons opté pour une simplification du niveau de détails à partir des nomenclatures des trois *BDs* cartographiques étudiées à la Section 3.3.1, en effectuant des regroupements de classes d'OCS basés à la fois sur la pertinence sémantique et sur les possibilités de détection à partir de séries temporelles Sentinel-2 (compte tenu de la répétitivité des acquisitions, de la couverture nuageuse et de la résolution spatiale) afin de disposer davantage de données de référence nécessaires pour l'apprentissage du classifieur *RF*. Nous avons ainsi pu constituer trois niveaux de nomenclatures à partir de ces trois *BDs* correspondant aux trois configurations qui orienteront l'ensemble des analyses effectuées dans chacune des deux zones d'étude *ZONE1* et *ZONE2*.

Le Tableau 3.6 présente les nomenclatures hiérarchiques proposées et utilisées au cours des travaux de classification supervisée dans les deux zones d'étude *ZONE1* et *ZONE2* au Cameroun. Ces nomenclatures sont réparties en trois niveaux : I, II et III.

3.3.3 configurations de nomenclatures étudiées

Afin de déterminer la contribution de la configuration de nomenclatures/légendes à fournir en entrée du système de classification avec un certain nombre et type de primitives uniquement spectrales et préalablement définies lors de la classification de séries temporelles comme celles fournies par Sentinel-2. La stratégie la plus simple, qui consiste à utiliser la seule *BDs* d'*OSM* à cinq classes, est étudiée. Toutefois, la possibilité de traiter des données de référence provenant de diverses sources, nous donne l'opportunité de faire une étude comparative de différentes nomenclatures. Pour ce faire, les *BDs* de l'*INC* (*BD INC*) et de *GLC* (*BD GLC*) détaillées à la Section 3.3 sont associées à la *BD INC*¹⁸ pour constituer de nouvelles données de référence telles que montrées dans le Tableau 3.6. Finalement, un total de trois configurations de nomenclatures : 1) *OSM*, 2) *OSM+INC*, et 3) *OSM+INC+GLC* comportant respectivement cinq, neuf et douze classes et constituées à partir des trois *BDs* utilisées dans le cadre des travaux, est proposé pour la classification supervisée de séries temporelles d'images satellitaires dans les deux zones d'étude *ZONE1* et *ZONE2*.

3.3.4 Pré-traitement des données de référence utilisées

La *BDs* de référence, aussi appelée base d'apprentissage, est indispensable à toute chaîne de traitement de données de télédétection telle que la chaîne *iota*². Elle permet principalement d'entraîner les algorithmes de classification des images. Elle repose sur la connaissance du terrain, acquise en amont des traitements numériques, idéalement synchronisée avec l'acquisition de l'image afin d'éviter les erreurs dues aux changements sur le territoire. Étant donné le contexte de cette thèse, le choix d'éléments présents dans la *BD INC* pour constituer ces cartes de vérité terrain (*VT*) s'est fait naturellement. Toutefois, cette *BDs* étant en cours de constitution, il s'est avéré que cette collecte n'avait réellement été utilement effectuée que sur les parties Nord et Ouest-Centre du pays.

Le choix de deux zones d'étude a donc été fait sur la base de la disponibilité des données collectées sur le terrain afin d'avoir la possibilité d'analyser visuellement les résultats sur une ortho-image préalablement générée à la Section 3.2.5 et les trois *BDs* de référence utilisées ont été mises en forme avec les trois niveaux de nomenclatures en respectant les critères pour leur utilisation dans la chaîne *iota*². Comme présenté à la Section 3.3.1, les données de référence utilisées pour l'apprentissage de l'algorithme de classification *RF* proviennent de trois *BDs* différentes. Un nettoyage et une harmonisation des données sont donc nécessaires.

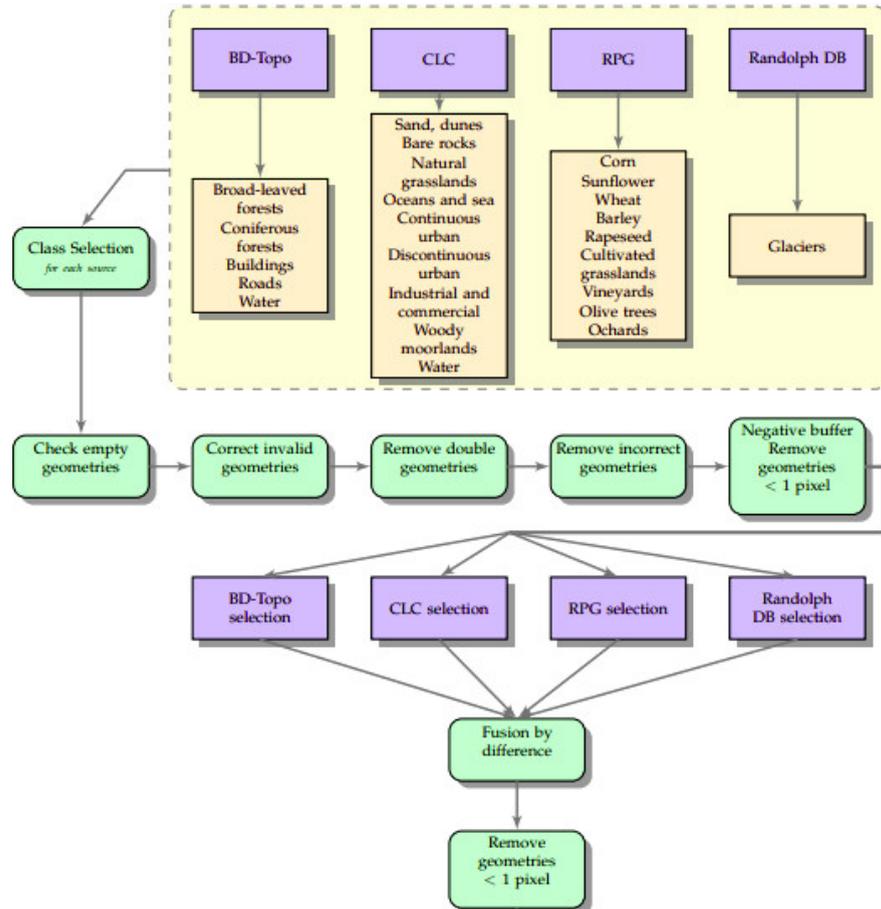
Pour ce faire, un ensemble d'étapes de pré-traitement a été conçu et implémenté dans une bibliothèque de logiciels libres (ARIAS et MORIN, 2017) afin que le processus soit automatique et reproductible. Ce processus de pré-traitement des données de référence se résume en deux principales étapes telles que présentée dans l'exemple de la Figure 3.21 dans laquelle les données sont issues de quatre *BDs* : 1) le nettoyage de chacune des sources (*BDs*) de données, et 2) leur fusion. L'étape de nettoyage commence par la sélection des polygones correspondant aux classes d'intérêt dans chaque

18. Dans la *BD INC*, seule la classe *Bati_Surfacique* a été fusionnée avec les classes des deux autres *BDs* : *BD OSM* et *BD GLC*. Le choix a été fait dans les études d'ajouter toutes les classes disponibles pour chaque *BDs*, pas seulement celles communes.

TAB. 3.6 – Nomenclature hiérarchique utilisée dans les deux zones d'étude.

Niveau I (OSM)	Niveau II (OSM+INC)	Niveau III (OSM+INC+GLC)	Classes utilisées	BDs utilisées
		<ul style="list-style-type: none"> 1 Végétation nue et clairsemée (VNC) 2 Végétation herbacée (VHB) 3 Forêt ouverte (FOU) 4 Forêt fermée (FFE) 5 Terres cultivées (TCU) 6 Arbustes (ARB) 7 Zones humides herbacées (ZHH) 	<ul style="list-style-type: none"> 1 Végétation nue et clairsemée 2 Végétation herbacée 3 Forêt ouverte 4 Forêt fermée 5 Terres cultivées 6 Arbustes 7 Zones humides herbacées 	GLC
	<ul style="list-style-type: none"> 1 Forêt (FRT) 2 Prairies (PRA) 3 Arbustes (ARB) 4 Agriculture (AGR) 	<ul style="list-style-type: none"> 1 Forêt 2 Prairies 3 Arbustes 4 Agriculture 		
	<ul style="list-style-type: none"> 5 Surfaces d'eau (SFE) 6 Zones humides (ZHU) 7 Rivières (RIV) 	<ul style="list-style-type: none"> 8 Surfaces d'eau (SFE) 9 Zones humides (ZHU) 10 Rivières (RIV) 	<ul style="list-style-type: none"> 8.1 Surfaces d'eau réservoir 8.2 Eau 9 Zones humides 10.1 Rivières 10.2 Voies navigables 10.3 Berges de rivières 	
<ul style="list-style-type: none"> 3 Eau (EAU) 			<ul style="list-style-type: none"> 11.1 Routes principales 11.2 Routes de liaison principales 11.3 Routes résidentielles 11.4 Routes secondaires 11.5 Routes de liaison secondaires 11.6 Routes de desserte 11.7 Routes tertiaires 11.8 Routes pistes 11.9 Routes nationales 11.10 Routes de stationnement 11.11 Routes non détectables 11.12 Routes non classées 	OSM
<ul style="list-style-type: none"> 4 Routes (RTE) 	<ul style="list-style-type: none"> 8 Routes (RTE) 	<ul style="list-style-type: none"> 11 Routes (RTE) 		
<ul style="list-style-type: none"> 5 Bâtiments (BTM) 	<ul style="list-style-type: none"> 9 Bâtiments (BTM) 	<ul style="list-style-type: none"> 12 Bâtiments (BTM) 	<ul style="list-style-type: none"> 12.1 Bâtiments 12.2 Bâti_Surfacique 	INC

source de données (Figure 3.21). Le nettoyage des données de référence s'est effectué en une séquence de six étapes distinctes : 1) Élimination des entités vides, 2) Correction des géométries invalides *e.g.* multi-polygones, multi-lignes etc., 3) Élimination des entités dupliquées, 4) Élimination des géométries invalides qui ne peuvent pas être corrigées, 5) Érosion des polygones (tampon négatif facultatif) pour éliminer les limites d'objets qui souvent correspondent à des pixels mixtes et 6) Élimination des polygones inférieurs à une emprise minimale (typiquement, la taille d'un pixel).



Source : (INGLADA et al., 2017b)

FIG. 3.21 – Pré-traitement des données de référence.

Les données provenant de chaque *BDs* sont pré-traitées avant d'être fusionnées dans les trois précédentes configurations de nomenclatures constituées et détaillées à la Section 3.3.3 qui constituent les *BDs* de référence finales utilisées tout au long des travaux de cette thèse.

Classification multi-temporelle de l'occupation du sol

Sommaire

4.1	Classification supervisée de séries temporelles d'images satellitaires	110
4.1.1	Introduction	110
4.1.2	Données en entrée du système de classification	113
4.2	Chaîne de traitement <i>iota</i>²	117
4.2.1	Origine de la chaîne <i>iota</i> ²	117
4.2.2	Fonctionnement de la chaîne <i>iota</i> ²	118
4.3	Problématique des données de référence insuffisantes	120
4.3.1	Données de référence insuffisantes en télédétection	120
4.3.2	Données de référence insuffisantes : Incomplétude et décalage	123
4.4	Présentation des expérimentations	124
4.4.1	Images satellitaires et données de référence	125
4.4.2	Stratégie d'échantillonnage pour l'apprentissage supervisé	125
4.4.3	Problématiques et stratégies adoptées	127
4.4.4	Configuration des paramètres du <i>RF</i>	128
4.4.5	Évaluation des résultats	129
4.4.6	Plan d'expérimentations	130
4.5	Auto-entraînement sur l'étendue d'une tuile Sentinel-2	132
4.5.1	Zone d'intérêt <i>T33PUL</i> (<i>ZONE1</i> , Nord)	132
4.5.2	Zone d'intérêt <i>T32NPL</i> (<i>ZONE2</i> , Ouest-Centre)	148
4.6	Stabilité du <i>Random Forest</i> sur l'étendue d'un bloc de tuiles Sentinel-2	165
4.6.1	Évaluation quantitative avec différents modèles sur la zone d'étude <i>ZONE1</i>	165
4.6.2	Artefacts dans les classifications	177
4.6.3	Comparaison pixel à pixel des classifications	182
4.6.4	Comparaison par région des distributions de classes des classifications	184
4.7	Sensibilité aux périodes de synthèse mensuelle de séries d'images Sentinel-2	187
4.7.1	Zone d'intérêt <i>T33PUL</i> (<i>ZONE1</i> , Nord)	187
4.7.2	Zone d'intérêt <i>T32NPL</i> (<i>ZONE2</i> , Ouest-Centre)	207
4.8	Comparaison des classifications avec les autres produits d'OCS	228
4.8.1	Comparaison des classifications et des produits d'OCS sur les zones d'intérêt	228
4.8.2	Enseignements tirés	232
4.9	Conclusion	234

Résumé du chapitre :

Les séries temporelles d'images à hautes résolutions Sentinel-1 et Sentinel-2 sont une entrée essentielle de la chaîne de traitement automatique *iota*² dédiée à la cartographie de l'OCS. Le processus de classification dépend en effet de l'algorithme de classification utilisé ainsi que des données fournies en entrée du système de classification.

Dans le contexte de la cartographie de l'OCS à partir de séries temporelles d'images satellitaires, les algorithmes de classification doivent savoir exploiter les variabilités spectro-temporelles fournies par les données satellitaires. En effet, la variabilité des paysages induite par les différents climats, les activités humaines, ou encore les différences pédologiques complexifie les apparences des classes d'OCS. En outre, cette variabilité est exacerbée lors de la classification sur de grandes étendues (YU et al., 2014a). Ainsi, ce chapitre présente différentes stratégies de classification supervisée de séries temporelles d'images Sentinel-2 - classification par tuile individuelle dans laquelle le modèle d'entraînement sur chaque tuile de la zone d'étude, est testé sur l'étendue de cette tuile et classification par bloc de tuiles dans laquelle le modèle d'entraînement sur chaque bloc de tuiles préalablement constitué sur la zone d'étude, est testé sur toute l'étendue de cette zone d'étude - et sur différents jeux de données constitués de séries temporelles d'images Sentinel-2 et leurs différentes synthèses mensuelles en entrée du système de classification.

La première partie introduit quelques généralités sur la classification supervisée avant de se focaliser sur les données satellitaires à fournir en entrée du système de classification. La deuxième partie présente la chaîne de traitement automatique *iota*² avec laquelle toutes les expériences de classification supervisée ont été menées. Dans un premier temps, l'origine de la chaîne, son principe, ses fonctionnalités et ses limites sont brièvement rappelés. Et dans un deuxième temps, le fonctionnement de la chaîne *iota*² dans son processus de production des cartes d'OCS est présenté plus en détail. La troisième partie présente la problématique liée à l'absence de données de référence suffisantes et de bonne qualité dans le processus de classification supervisée. Dans un premier temps, les généralités sur l'insuffisance de données de référence en télédétection sont présentées. Dans un deuxième temps, les conséquences de cette insuffisance sur le processus de classification sont abordées. La quatrième partie présente les configurations des trois études de : 1) l'auto-entraînement sur l'étendue d'une tuile, 2) la stabilité du RF sur l'étendue d'un bloc de tuiles Sentinel-2 et 3) la sensibilité des performances de classification aux différentes périodes de synthèse mensuelle de séries d'images Sentinel-2 dont les résultats sont respectivement détaillés dans les cinquième, sixième et septième parties. Ensuite, la comparaison des différents résultats de classification avec les autres produits d'OCS est effectuée dans la huitième partie. Enfin, une dernière partie conclut ce chapitre.

4.1 Classification supervisée de séries temporelles d'images satellitaires

4.1.1 Introduction

L'objectif d'un apprentissage supervisé est d'apprendre automatiquement des règles pour prédire les étiquettes de nouveaux échantillons. L'ensemble des règles est appris à partir d'exemples fournis par une donnée de référence (Figure 4.1). Les échantillons contenus dans la donnée de référence sont divisés au cours de l'étape d'échantillonnage en deux sous-ensembles. D'une part, les échantillons

d'apprentissage sont utilisés comme connaissance à priori sur les classes d'OCS. D'autre part, les échantillons test servent lors de la phase d'évaluation, décrite dans la Section 2.6.

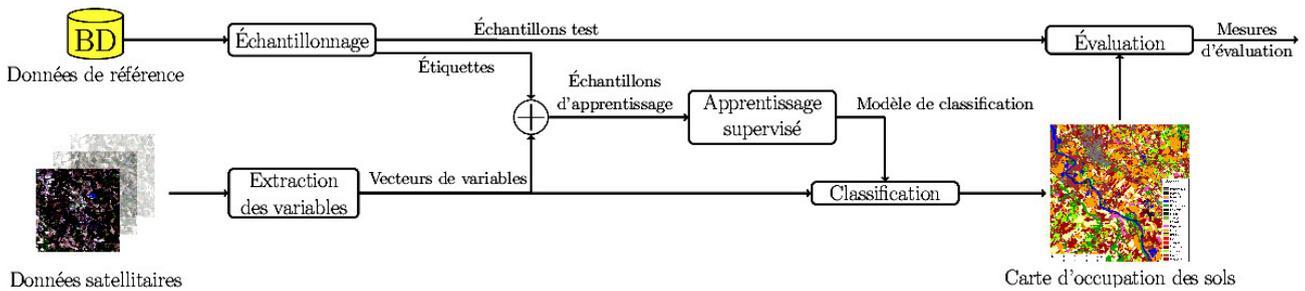


FIG. 4.1 – Processus de classification supervisée.

L'étape centrale du processus est l'apprentissage supervisé. A partir des échantillons d'apprentissage, l'algorithme de classification apprend un modèle de classification. La règle de décision définie par le modèle permet de prédire les classes d'OCS pour de nouveaux échantillons.

Une des principales difficultés de la phase d'apprentissage est de trouver le compromis entre un modèle trop simple et un modèle trop spécifique aux échantillons d'apprentissage. Le modèle peut décrire parfaitement les échantillons d'apprentissage, mais être incapable de prédire correctement les classes de nouveaux échantillons qui n'ont pas été utilisés pour le construire. Un modèle peu stable qui apprend par coeur les données d'apprentissage sans avoir aucune capacité de généralisation, fait du sur-apprentissage (*over-fitting*). Au contraire, un modèle trop simple est incapable de saisir les relations pertinentes entre les échantillons d'apprentissage. Il commet alors de nombreuses erreurs sur les échantillons d'apprentissage, et fait du sous-apprentissage (*under-fitting*). Dans les deux cas, le modèle construit est incapable de généraliser et de prédire l'étiquette de nouveaux échantillons.

Ce problème est aussi connu sous le nom de compromis biais-variance. Le biais d'un algorithme est caractérisé par son erreur sur l'ensemble des données d'apprentissage, tandis que la variance d'un algorithme correspond à l'écart entre l'erreur faite sur les données d'apprentissage et l'erreur faite sur les données test. Le compromis biais-variance consiste donc à trouver un équilibre entre la complexité du modèle et sa capacité à généraliser.

La Figure 4.2 représente trois fois le même problème de classification à deux classes (*bleue* et *verte*) pour lequel différentes frontières de décision, *en pointillé noir*, sont dessinées. La Figure 4.2A montre un modèle trop simple, pour lequel le biais est élevé, *i.e.* trois échantillons sont mal classés. Le modèle de la Figure 4.2B montre un exemple de sur-apprentissage où l'ensemble des échantillons sont parfaitement classés. Ce modèle est caractérisé par une forte variance car l'ajout ou la suppression d'un échantillon modifierait totalement la frontière de décision. Enfin, la Figure 4.2C montre un bon compromis entre le biais de l'algorithme et la variance. La frontière de décision devrait permettre une bonne généralisation pour prédire l'étiquette de nouveaux échantillons.

Les échantillons d'apprentissage jouent un rôle essentiel pour obtenir un bon compromis biais-variance. Les échantillons d'apprentissage sont décrits par les valeurs des vecteurs de variables extraits des données satellitaires. Les termes primitives ou attributs sont aussi utilisés pour parler de variables calculées à partir des données satellitaires. Les algorithmes de classification utilisent alors ces échantillons afin de construire leur règle de décision.

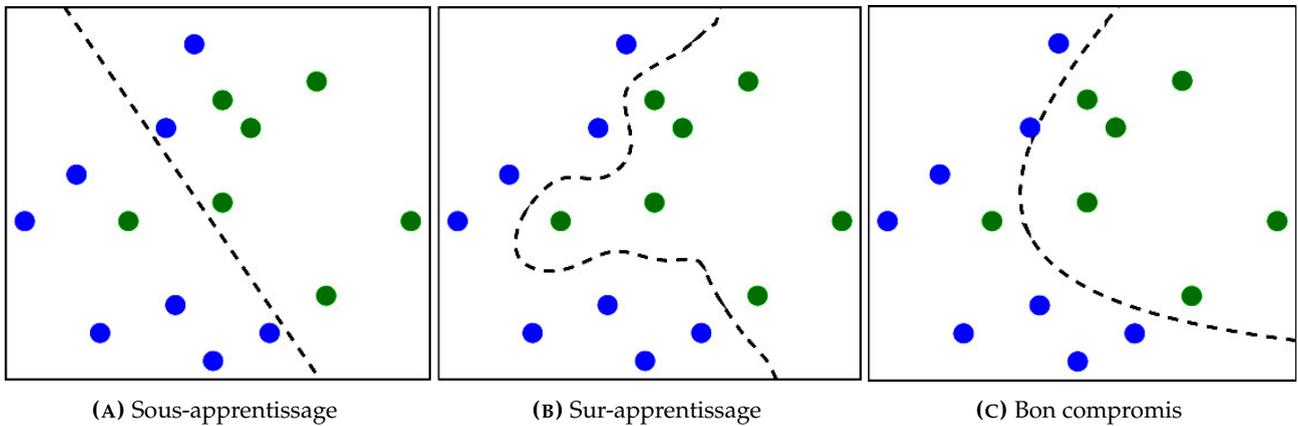


FIG. 4.2 – Illustration des problèmes de sur-apprentissage et sous-apprentissage.

les échantillons d'apprentissage doivent être représentatifs de la population sur laquelle le modèle sera appliqué. Ils doivent entre autre décrire les apparences multiples des classes. Par exemple, une classe surface urbaine doit idéalement décrire l'ensemble des toits apparents.

Deux paramètres importants du problème de la classification supervisée sont alors 1) n le nombre d'échantillons d'apprentissage, et 2) p la dimension du vecteur de variables. Augmenter les valeurs de n et p permet généralement d'apprendre un modèle plus complexe tout en contrôlant la variance.

Cependant, augmenter la dimension p du vecteur n'est pas toujours une bonne solution. Certaines méthodes traditionnelles, notamment les méthodes statistiques, sont mises en défaut lorsque la dimension p du problème devient trop élevée, éventuellement plus grande que n . Ce phénomène connu sous le nom de malédiction de la dimension (*curse of dimensionality* ou *Hughes phenomenon*) fait diminuer les performances des algorithmes de classification (HUGHES, 1968). Si le nombre d'échantillons est trop peu important devant le nombre de variables, les échantillons vont être isolés dans un espace de grande dimension, compliquant les regroupements d'échantillons similaires.

De manière générale, l'augmentation du nombre d'échantillons d'apprentissage assure donc une meilleure description des apparences des classes et limite la malédiction de la dimension. Ainsi, les performances de la classification augmentent généralement avec le nombre d'échantillons. Plusieurs études dans la littérature ont tenté de définir le nombre optimal d'échantillons nécessaires pour l'apprentissage, notamment en fonction de p . La règle des $30p$, *i.e.* utilisé au moins $30p$ échantillons d'apprentissage par classe, fait souvent référence (FOODY et MATHUR, 2004a).

Cependant, des études montrent qu'un nombre inférieur d'échantillons bien informatifs, *e.g.* les échantillons à la frontière de classes (FOODY et MATHUR, 2004b), peut aussi permettre de bien séparer les classes pour certains types d'algorithmes (PIPER, 1992; NIEL, MCVICAR et DATT, 2005). Par ailleurs, les récents travaux de (LI et al., 2014) concluent qu'une soixantaine d'échantillons d'apprentissage par classe suffit à obtenir une précision importante pour une quinzaine d'algorithmes de classification. Cependant, ces études sur le nombre optimal d'échantillons nécessaires sont souvent réalisées dans des espaces de petites dimensions, *e.g.* $p = 3$ (FOODY et MATHUR, 2004a), bien inférieures au nombre de variables qu'il est possible d'extraire des séries temporelles d'images satellitaires.

4.1.2 Données en entrée du système de classification

Dans le cadre de l'apprentissage supervisé, les données fournies en entrée du système de classification sont les échantillons d'apprentissage (Figure 4.1). Ces derniers sont décrits par un vecteur de variables extrait des données satellitaires, ainsi que d'une classe d'OCS extraite des données de référence.

Bien qu'il soit possible d'utiliser seulement les bandes spectrales (*BS*) (AKBARI et al., 2006), il est courant d'enrichir cette information de variables calculées à partir des images satellitaires : ce sont les primitives ou néo-canaux. Elles permettent d'améliorer la distinction des OCS, et sont généralement divisées en trois catégories : 1) les primitives spectrales qui combinent l'information de différentes *BS*, 2) les primitives spatiales qui utilisent le voisinage (*e.g.* géométrie ou texture) (HARALICK, 1979; LV et al., 2017; TRIAS-SANZ, 2006), et 3) les primitives temporelles extraites à partir de séries temporelles d'images satellitaires. L'apport des primitives spatiales sur les performances de classification a été démontré de nombreuses fois, grâce à leur prise en compte du voisinage et de leurs effets de filtrage. L'information spatiale, et de manière plus générale contextuelle, est notamment importante pour les images à très haute résolution (*THR*) spatiale (BLASCHKE, 2010). Elle l'est toutefois moins pour des images à 20 ou 30 mètres de résolution spatiale. De plus, la grande nouveauté des séries temporelles d'images satellitaires repose sur la dimension temporelle; mais le choix a été fait de se focaliser pour ces études sur l'apport de l'information temporelle qui est ici sous une forme brute (données brutes) sans toutefois être sous forme d'indices temporels (INGLADA et al., 2017b).

Ce chapitre discute en particulier du choix de la configuration de *BDs* de référence à fournir en entrée du système de classification. Une première partie est dédiée aux stratégies mises en place dans la littérature pour construire le vecteur de variables utile au processus de classification supervisée. Puis, une seconde partie décrit les primitives spectrales et temporelles.

4.1.2.1 Choix des variables en télédétection

Plusieurs stratégies sont possibles afin de choisir les variables à extraire des images satellitaires. Une première stratégie consiste à utiliser seulement certaines variables en lien avec le problème de classification, *e.g.* des indices pour caractériser la végétation (XIAO et al., 2005). Cependant, cette stratégie peut conduire à l'utilisation d'un jeu de variables sous optimal si les primitives extraites ne sont pas suffisantes.

Une seconde stratégie consiste alors à calculer des centaines de primitives (MURA et al., 2010; HUANG et ZHANG, 2013). Malheureusement une majorité des algorithmes de classification est sensible au phénomène de malédiction de la dimension (*curse of dimensionality* ou *Hughes phenomenon*) qui survient lorsque la dimension du vecteur de variables devient trop élevée par rapport au nombre d'échantillons d'apprentissage, et donc incapable de gérer de grands volumes de données. Par conséquent, des méthodes de réduction et de sélection d'attributs ont été utilisées.

Les méthodes de réduction de dimension comme l'Analyse par Composantes Principales (*ACP*) transforment l'information physique des images satellitaires afin de réduire le nombre de variables et de supprimer l'information redondante (POTGIETER et al., 2007). Une autre approche consiste à sélectionner le meilleur sous-ensemble de variables parmi celles calculées (CAMPS-VALLS et al., 2011), en se fondant par exemple sur le score d'importance des variables calculé par le *RF* (GRESSIN, MALLET et PAPANODITIS, 2013; PAGET, GRESSIN et MALLET, 2015). Une autre stratégie de sélection consiste à s'appuyer sur des connaissances a priori du problème. Par exemple, il est courant lors de

la classification de classes de cultures de sélectionner des images à deux saisons différentes afin de maximiser les différences spectrales entre les classes, *e.g.* cultures d'hiver et cultures d'été (RODRIGUEZ-GALIANO et al., 2012b; ROGAN, FRNAKLIN et ROBERTS, 2002). Dans ce cas, une connaissance experte est nécessaire afin de déterminer le meilleur sous-ensemble de variables à sélectionner. En plus d'éviter la malédiction de la dimension, la réduction du nombre de variables permet aussi de réduire les temps d'apprentissage. Pourtant, ces méthodes sont coûteuses et complexes à mettre en place de manière opérationnelle. La sélection de primitives est souvent spécifique au jeu de données. D'une part, les variables sélectionnées pour une année ne formeront peut être pas le meilleur ensemble pour l'année suivante. D'autre part, les variables sélectionnées dans une zone éco-climatique et topographique spécifique ne conviendront peut être pas pour une zone d'étude différente (RODES, 2016).

Le développement d'algorithmes de classification moins sensibles aux espaces de grande dimension permet d'envisager des stratégies plus faciles à automatiser et plus adaptées aux problèmes de classification sur de grandes étendues. Avec l'utilisation de ces classifieurs, une des plus simples stratégies consiste à garder toute l'information temporelle et spectrale contenue dans les séries temporelles, *i.e.* chaque *BS* de toutes les images satellitaires. Les profils spectraux-temporels extraits pour différentes classes d'OCS peuvent alors être suffisants. Cependant, la contribution de certaines primitives est encore incertaine dans le contexte de séries temporelles d'images à hautes résolutions (GÓMEZ, WHITE et WULDER, 2016). De plus, l'ajout de primitives peut aider à gérer la forte variabilité des paysages lors d'études sur de grandes étendues. Par exemple, l'ajout d'information radar peut permettre de mieux prendre l'ensemble des apparences de classes d'OCS.

Pour des algorithmes moins sensibles aux problèmes de grande dimension, il pourrait être donc intéressant de calculer un grand nombre de primitives et laisser les algorithmes de classification choisir l'information la plus pertinente dans cet espace (VIEIRA et al., 2012). Cette stratégie n'est pas adoptée dans ces travaux étant donné que l'introduction d'un grand nombre de variables augmente les temps d'apprentissage et d'inférence, et nécessite aussi de fortes capacités de stockage. Aucune étude n'a été effectuée sur les jeux de variables permettant d'atteindre la précision maximale. Les quatre variables *NDVI*, *NDWI*, *NDBI* et *Brightness* ont été utilisées en plus des *BS* de séries temporelles d'images Sentinel-2 dans la chaîne *iota*² (INGLADA et al., 2017b).

4.1.2.2 Primitives spectrales et temporelles

L'ajout d'informations supplémentaires aux *BS* brutes/natives est donc courant dans la littérature sur la classification de données satellitaires : utilisation de données exogènes comme le *MNT* (FRANKLIN, 1998; RODRIGUEZ-GALIANO et al., 2012b), calcul de variables bio-physiques (WALDNER et al., 2015b), introduction de règles expertes (OSMAN, INGLADA et DEJOUX, 2015; WALDNER, CANTO et DEFOURNY, 2015a), ou encore approches basées objets (BLASCHKE, 2010). Bien que l'ensemble de ces approches ait montré un apport potentiel pour la cartographie de l'OCS, de nombreuses questions méthodologiques persistent. A titre d'exemple, considérons l'ajout des trois composantes du *MNT* – *altitude*, *pente* et *exposition* – à une série temporelle d'images satellitaires composées de dix images représentées par dix *BS*. La dimension du vecteur de variable est donc de $10 \times 10 + 3 = 103$ dimensions où l'information du *MNT* est sous-représentée, et donc a une influence limitée (LUCAS et al., 2007a). Utiliser le *MNT* comme connaissance a posteriori en fixant des seuils sur certaines classes est une approche compliquée puisque les seuils doivent continuellement être mis à jour.

Cependant, ces informations ainsi que la prise en compte du contexte spatial ou de manière plus générale les approches basées objets (BLASCHKE, 2010) n'ont pas été étudiées dans le cadre de ce manuscrit. La suite de cette section est donc dédiée aux primitives spectrales et temporelles.

4.1.2.2.1 Primitives spectrales Le calcul de primitives spectrales combine différentes *BS* en s'appuyant sur les propriétés physiques des *BS* pour améliorer la discrimination entre les classes. Une des propriétés physiques bien connue, et exploitée, concerne la végétation qui a une réponse faible dans le *visible* due à la photo-synthèse, mais une réponse forte dans le *proche infra-rouge* à cause de la structure des plantes (TUCKER, 1979). Ainsi, l'indice de *NDVI* – différence normalisée entre les *BS rouge* et *infra-rouge* – permet d'augmenter la discrimination des classes de végétation avec le sol nu et l'eau. Il est de plus corrélé à des propriétés de la végétation comme l'état de santé et la phénologie des plantes, la biomasse ou encore à la notion de rendement (DEFRIES et TOWNSHEND, 1994; SENF et al., 2015). De manière similaire, l'indice de *NDWI* permet d'augmenter la discrimination de l'eau du sol et de la végétation (MCFEETERS, 1996), et l'indice de *NDBI* permet d'améliorer la détection de zones urbaines (ZHA, GAO et NI, 2003). La Figure 4.3 montre une image satellitaire Sentinel-2 en fausse couleur ainsi que les indices de *NDVI*, *NDWI* et *NDBI* associés.

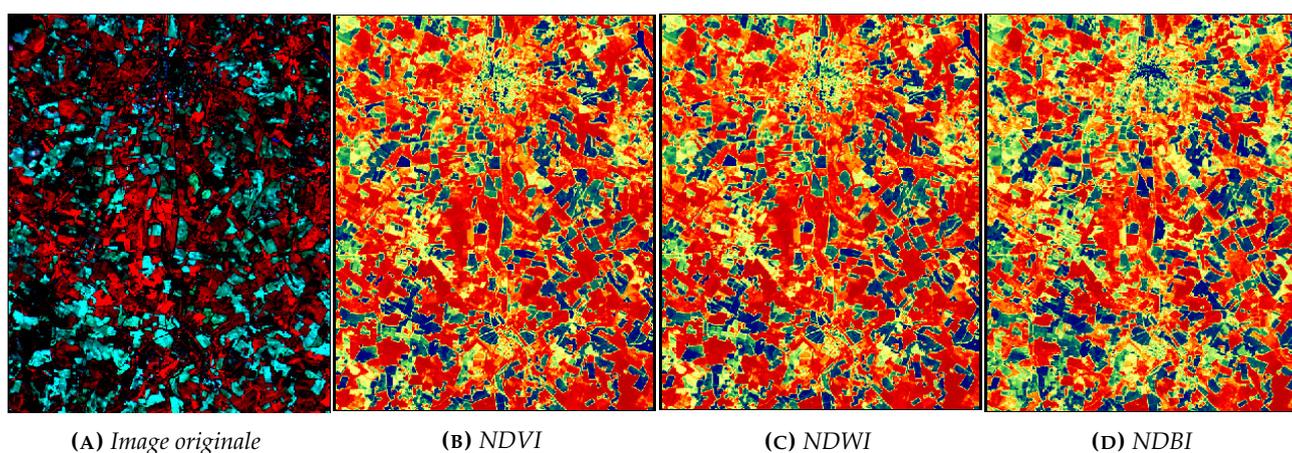


FIG. 4.3 – Exemple d'indices spectraux. La couleur *rouge* représente des valeurs faibles de l'indice, et le *bleu* des valeurs élevées.

De plus, des indices spectraux spécifiques aux capteurs ont été proposés dans plusieurs travaux. Par exemple, les coefficients *tasseled cap* calculés pour les images Landsat permettent la caractérisation de zones de cultures agricoles à travers trois indices décorrélés (*Brightness*, *Greenness*, et *Wetness*) (BAIG et al., 2014; CRIST et CICONE, 1984; HUANG et al., 2002b; KAUTH et THOMAS, 1976).

Ainsi, l'utilisation de primitives peut aider les algorithmes de classification. Pour les algorithmes de classification linéaires comme le *SVM* linéaire, la frontière de décision recherchée est obtenue par des combinaisons linéaires des variables. L'utilisation de primitives calculées par des combinaisons non-linéaires des *BS* peut donc faciliter la recherche de la frontière de décision. Pour les algorithmes de classification non-linéaires, la frontière de décision est simplifiée par l'ajout d'information non-linéaire, et donc la capacité de généralisation peut être augmentée, *e.g.* augmentation de la marge du *SVM*.

Dans la littérature, des centaines de primitives spectrales ont été proposées notamment pour l'étude de la végétation (MRÓZ et SOBIERAJ, 2004; SILLEOS et al., 2006; YEOM, HAN et KIM, 2013)¹. Suite à

1. indexdatabase.de

plusieurs études préliminaires, quatre indices ont été sélectionnés pour les travaux de cette thèse. Le détail de toutes ces primitives spectrales est donné par le Tableau 4.1.

TAB. 4.1 – Description des primitives spectrales utilisées.

Nom	Formule	Commentaires
<i>Normalized Difference Vegetation Index</i>	$NDVI = \frac{PIR-R}{PIR+R}$	(ROUSE et al., 1973) (MCFEETERS, 1996) a proposé la même année la formulation suivante : $NDWI = -NDBI$. Les deux expressions sont utiles pour la détection du contenu liquide de la végétation. Wilson and (GAO, 1996) ont aussi nommé la formulation de Gao <i>Normalized Difference Moisture Index (NDMI)</i> .
<i>Normalized Difference Water Index*</i>	$NDWI = \frac{V-PIR}{V+PIR}$	(XU, 2006)
<i>Normalized Difference Built-up Index*</i>	$NDBI = \frac{SWIR1-NIR}{SWIR1+NIR}$	Les coefficients <i>tasseled cap</i> sont des combinaisons linéaires entre les bandes spectrales, proposés initialement pour les images Landsat (CRIST et CICONE, 1984) (KAUTH et THOMAS, 1976)
<i>Brightness</i>	$Brightness = 0,3561 \times B + 0,3972 \times V + 0,3904 \times R + 0,6966 \times PIR + 0,2286 \times MIR1 + 0,1596 \times MIR2$	

Ubl : ultra-bleue (aérosol) ; B : bleue ; V : verte ; R : rouge ; PIR : proche infra-rouge ; MIR : moyen infra-rouge

4.1.2.2 Primitives temporelles Contrairement aux primitives spectrales, les primitives temporelles ont reçu moins d'intérêt. Cependant, certaines ont prouvé leur capacité à améliorer les performances de classification, particulièrement pour la cartographie de la végétation (KAUTH et THOMAS, 1976; PITTMAN et al., 2010; VALERO et al., 2016). Cette partie se propose de les décrire.

Calculables grâce au fort temps de revisite des nouvelles données satellitaires, les primitives temporelles extraites des séries temporelles peuvent aider le classifieur pour discriminer les OCS qui évoluent au cours du temps comme les cultures (WALDNER, CANTO et DEFOURNY, 2015a). L'extraction de primitives temporelles est donc souvent réalisée à partir des profils temporels d'indices de végétation comme le *NDVI*. Deux stratégies sont traditionnellement adoptées.

La première stratégie consiste à extraire des valeurs significatives des profils temporels comme le maximum, l'amplitude, ou encore la moyenne (ARVOR et al., 2011; PITTMAN et al., 2010; VALERO et al., 2016). Ces valeurs sont généralement représentatives du cycle phénologique des plantes lorsqu'elles

sont calculées à partir de l'indice de végétation, *e.g.* un maximum de *NDVI* correspond à la croissance maximale de la plante.

Une seconde stratégie consiste à extraire les paramètres phénologiques en modélisant les profils temporels d'indices de végétation. Basée sur ce principe, *TIMESAT* est la méthode la plus connue (JÖNSSON et EKLUNDH, 2002). Le logiciel associé à *TIMESAT* permet le calcul de neuf paramètres phénologiques déduits du profil de *NDVI* comme le début de croissance, la valeur du pic ou la longueur du plateau. Au moins trois années de données acquises à dates régulières sont nécessaires pour 1) estimer le nombre de saisons, et 2) ajuster le profil de *NDVI* à un modèle. *TIMESAT* a principalement été utilisé pour des séries temporelles à basse résolution spatiale, notamment les données MODIS (JIA et al., 2014b). D'autres méthodes d'ajustement ont aussi été proposées pour les données satellitaires (BECK et al., 2006; EERENS et al., 2014; ZHANG et al., 2003).

4.2 Chaîne de traitement *iota*²

4.2.1 Origine de la chaîne *iota*²

En télédétection, le problème du traitement d'images satellitaires couvrant de très grandes étendues (par rapport à l'emprise d'une image) demeure une difficulté. En effet, il faut gérer de nombreux aspects tels que la différence de dates d'acquisition entre les différentes images couvrant l'intégralité de l'étendue définie ou encore le recouvrement entre les tuiles, causé par le découpage en segments des acquisitions et la projection en zones *UTM*. Ainsi, la complexité du problème croît avec la taille de la zone d'étude choisie, car le nombre de tuiles en est proportionnel.

Dans cette optique, le développement de l'Infrastructure pour l'OCS par Traitement Automatique Incorporant les *Orfeo ToolBox (OTB) Applications (iota*²*)* a été initié par le Centre d'Etudes Spatiales de la Biosphère (CESBIO) de Toulouse, dans le cadre des activités du Centre d'Expertise Scientifique OCS (CES OSO) du Pôle Surfaces Continentales THEIA², pour produire des classifications d'OCS à partir de séries temporelles d'images satellitaires issues d'un ou plusieurs capteurs et de données de référence provenant d'une ou plusieurs *BDs*. *Iota*² permet la gestion de gros volumes de données, provenant de différentes tuiles, de différentes dates d'acquisitions et sur de grandes étendues comme la France métropolitaine (Corse incluse). Disponible comme logiciel libre, la chaîne est principalement dédiée à l'exploitation de séries temporelles d'images Sentinel-2 éventuellement associées à des données Sentinel-1, en combinaison avec une donnée de référence, se basant sur une méthodologie de classification par pixel qui utilise des algorithmes classiques d'apprentissage automatique tels que les forêts aléatoires (*Random Forest (RF)*) décrites à la Section 2.5.1. Elle offre la possibilité de configuration éco-climatique (INGLADA et al., 2017b), en produisant des cartes à résolution décimétrique (cf. la résolution de la donnée Sentinel d'entrée), potentiellement à large échelle. La chaîne *iota*² intègre également des traitements spécifiques aux séries temporelles d'images optiques comme le *gapfilling* (remplissage de vides) temporel. *Iota*² a été créée pour être exécutée indifféremment sur les systèmes d'exploitation *POSIX (Portable Operating System Interface – UNIX)*. Il est possible de paralléliser les traitements et de l'utiliser à la fois sur des machines multi-coeurs à mémoire partagée et sur des clusters de calcul à haute performance avec des centaines de noeuds (INGLADA, 2016a). Le principal produit de la chaîne *iota*² jusqu'à présent est la carte d'OCS de la France métropolitaine (*OSO*) issue d'une fusion de *BDs* existantes (*CORINE Land Cover (CLC)*, Registre Parcellaire Graphique (*RPG*), *BD*

2. <https://www.theia-land.fr/ceslist/ces-occupation-des-sols/>

Topo de l'IGN, *BDs* d'*OpenStreetMap* (*OSM*), etc.) à partir d'images Landsat-8 et Sentinel-2 à 10 m et 20 m de résolution spatiale respectivement (<http://osr-cesbio.ups-tlse.fr/~oso/>). Des applications sur d'autres territoires comme l'île de la Réunion sont actuellement menées par le Centre de Coopération Internationale et Recherche Agronomique pour le Développement (CIRAD).

4.2.2 Fonctionnement de la chaîne *iota*²

La méthodologie générale de classification appliquée par la chaîne *iota*² se fonde sur une procédure classique de classification supervisée telle que montrée dans la Figure 4.4, avec l'avantage de donner la possibilité de traiter de gros volumes de données et surtout des séries temporelles sur de très grands territoires de manière entièrement automatique. Du fait de cette approche automatique, la chaîne *iota*² a été conçue pour être applicable indépendamment de la nomenclature des classes du paysage et par conséquent aucune sélection de date en termes de saison ou de phénologie de la végétation n'est appliquée. Il est donc conseillé d'utiliser autant d'images que possible afin de mieux caractériser le cycle annuel de couverture du sol (INGLADA et al., 2017b).

*Iota*² est un logiciel récent et en développement actif. Il est relativement facile à utiliser par des non-experts. Son lancement repose sur un fichier de configuration qui ne nécessite pas de connaissances détaillées sur les méthodes mises en oeuvre. Néanmoins, la chaîne reste difficile à installer et la documentation utilisateur demeure succincte pour une prise en main autonome.

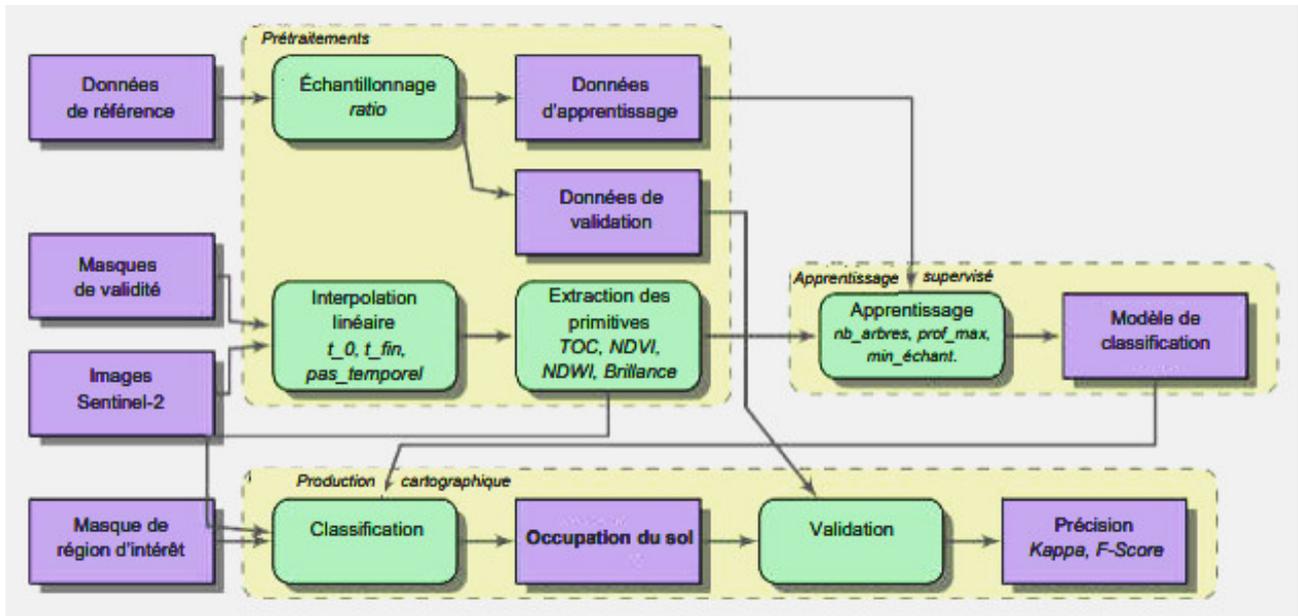
Les entrées du traitement montrées dans la Figure 4.4 sont réparties en quatre éléments : 1) les données de référence (échantillons étiquetés et géoréférencés correspondant aux différentes positions géographiques pour lesquelles la classe d'OCS est connue), 2) les séries temporelles d'images satellitaires de niveau 2A (*L2A*) (corrigées géométriquement et radiométriquement), 3) les masques de validité des séries temporelles d'images. Chaque image correspondant à une date est accompagnée d'un masque indiquant les pixels valides et invalides (détection de nuages, ombre de nuages, saturation, hors de portée du satellite), et 4) comme entrée facultative, un masque de région d'intérêt (*Region Of Interest* (*ROI*)) permettant d'exclure des zones où nous ne voulons pas de classification. Dans la Figure 4.4, les six boîtes *vertes* indiquent les six étapes principales du processus de classification d'OCS avec la chaîne *iota*² dont l'ordre de traitement est le suivant : 1) Échantillonnage, 2) Interpolation linéaire temporelle, 3) Extraction des primitives, 4) Apprentissage, 5) Classification, et 6) Validation.

4.2.2.1 Échantillonnage

*Iota*² sépare aléatoirement les données de référence en données d'apprentissage et données de validation suivant le ratio demandé dans le fichier de configuration ; la séparation s'effectuant au niveau du polygone et non au niveau du pixel : les pixels provenant d'un même polygone, avec des caractéristiques similaires, ne sont ainsi pas utilisés à la fois pour l'apprentissage et la validation, ce qui biaiserait l'évaluation de la qualité des classifications vers des résultats quantitatifs optimistes.

4.2.2.2 Gestion des masques / Interpolation temporelle

Les séries temporelles des images sont pré-traitées avec du *gapfilling* et du ré-échantillonnage temporel afin d'assurer l'homogénéité spatiale et temporelle. L'approche consiste en une interpolation linéaire des pixels invalides en utilisant les valeurs de réflectance de surface des dates précédentes et suivantes aux dates avec des nuages. Concernant le ré-échantillonnage temporel, l'interpolation linéaire est appliquée sur toutes les valeurs de réflectance de surface de toutes les dates (pixels valides



Source : Traduit de (INGLADA et al., 2017b)

FIG. 4.4 – Schéma fonctionnel du processus de production des cartes d'OCS.

et invalides), afin d'avoir des dates communes pour tous les pixels de la zone d'étude. Il s'agit alors de produire un échantillonnage temporel régulier dont le pas est défini par l'utilisateur.

4.2.2.3 Extraction des primitives

Les séries temporelles obtenues sont utilisées pour le calcul d'indices spectraux (*Normalized Difference Vegetation Index (NDVI)*; *Normalized Difference Water Index (NDWI)* et la *luminosité (Brightness)*) de chaque pixel à chaque date. Ces indices viennent s'ajouter aux données de réflectance (de surface), ce qui peut permettre d'améliorer les résultats des classifications. Ces indices servent en effet à mettre en évidence des propriétés particulières des surfaces observées comme la présence de végétation avec le *NDVI* et de l'eau et des zones humides avec le *NDWI* (BAGHDADI et ZRIBI, 2016).

4.2.2.4 Apprentissage

Les données d'apprentissage sont utilisées pour apprendre au classifieur à identifier les classes d'OCS. C'est lors de cette étape que le modèle de classification est produit. *Iota²* se fonde en particulier sur l'algorithme de classification *Random Forest (RF)* (BREIMAN, 2001) détaillé à la Section 2.5.1, qui a montré des précisions globales supérieures ou similaires à autres méthodes traditionnelles comme les arbres de décision et les *SVM*. De plus, le classifieur *RF* demande des temps de traitement plus courts avec un paramétrage plus simple (PELLETIER et al., 2016; INGLADA et al., 2015a; RODRIGUEZ-GALIANO et al., 2012a; GISLASON, BENEDIKTSSON et SVEINSSON, 2006b).

4.2.2.5 Classification / Inférence

Cette étape consiste à affecter des classes particulières à tous les pixels de l'image en utilisant les séries temporelles de réflectance de surface et d'indices spectraux ainsi que le modèle de classification. Le produit de cette étape est une carte d'OCS comportant les mêmes classes que les données d'apprentissage. On peut noter que les différents ré-échantillonnages (spatiaux et temporels) sont, ici effectués à la « volée » (même si la sauvegarde du cube de données généré est possible sur demande).

4.2.2.6 Évaluation / Validation

La qualité des cartes d'OCS produites par la chaîne *iota*² est évaluée à l'aide d'un ensemble d'indices dérivés d'une matrice de confusion (Section 2.6.1) et calculés à partir des données de validation utilisées au niveau pixellaire.

Dans un contexte d'automatisation de la chaîne de traitement *iota*² pour la cartographie précise de l'OCS sur de grandes étendues avec l'algorithme du *RF* qui est plus robuste à la présence de données mal étiquetées (PELLETIER, 2017), un grand nombre de données de référence est nécessaire y compris celles pour lesquelles certaines étiquettes sont incertaines. L'absence d'un nombre suffisant de données de référence réduit le nombre d'échantillons d'apprentissage qui vont être isolés dans un espace de grande dimension (HUGHES, 1968), compliquant ainsi les regroupements d'échantillons similaires. Par ailleurs, la réduction du nombre d'échantillons d'apprentissage ne permet pas une meilleure description des classes d'OCS diminuant ainsi les performances. Dans la suite, la problématique du manque de données de référence dans le processus de classification supervisée est abordée.

4.3 Problématique des données de référence insuffisantes

Le problème majeur rencontré dans les travaux de cette thèse est lié à l'absence de données de référence suffisantes et de bonne qualité dans le processus de classification supervisée. Pour outrepasser cette difficulté, le choix a été fait dans ces travaux d'utiliser malgré tout les données vecteurs disponibles pour chaque classe d'OCS étudiée (voir le Tableau 3.6). On s'intéresse ici aux problématiques liées à l'utilisation de données de référence insuffisantes pour l'apprentissage du classifieur et les conséquences de cette utilisation sur l'évaluation de la classification. Les généralités sur l'insuffisance des données de référence utilisées et les problèmes de sur-généralisation du classifieur en télédétection sont d'abord introduites puis, les conséquences de cette insuffisance sur le processus de classification, notamment l'incomplétude et les décalages au niveau des cartes d'OCS produites, sont abordées.

4.3.1 Données de référence insuffisantes en télédétection

Dans le domaine de la télédétection, la difficulté de disposer des données de référence nécessaire en quantité suffisante est principalement dû au fait que la création de ces données est une tâche fastidieuse et coûteuse. En effet, la création d'une *BDs* de référence consiste à relever la réalité du terrain (collecte ou photo-interprétation). Cette *BDs* prend alors la forme de polygones délimitant des surfaces homogènes bien renseignées. De plus en plus souvent, on dispose déjà sur un territoire donné d'un certain nombre de *BDs* (d'autorités, participatives, scientifiques etc.) existantes et répondant partiellement aux besoins. Cette *BDs* doit être suffisamment fiable pour être considérée comme la « vérité », car elle servira autant à calibrer les modèles de représentation cartographiques qu'à évaluer les résultats.

En amont de toute cartographie se trouve la question de la clarification de l'information que l'on souhaite représenter et qui est attendue par les utilisateurs de la carte. Il en découle alors **un thème (ou titre) de carte**. Ensuite une liste des différents types de surfaces/d'objets souhaités être reconnus au travers de la carte doit être exprimée par les utilisateurs, **en cohérence** avec le thème de la carte uniquement. Par exemple, on ne peut pas mélanger dans une même carte différents niveaux d'information comme la discrimination des surfaces recouvertes de végétation de celles laissées en

sol nu, d'une part, et la détection des cultures atteintes de maladie, d'autre part. Cette liste est **la nomenclature de base de la carte**.

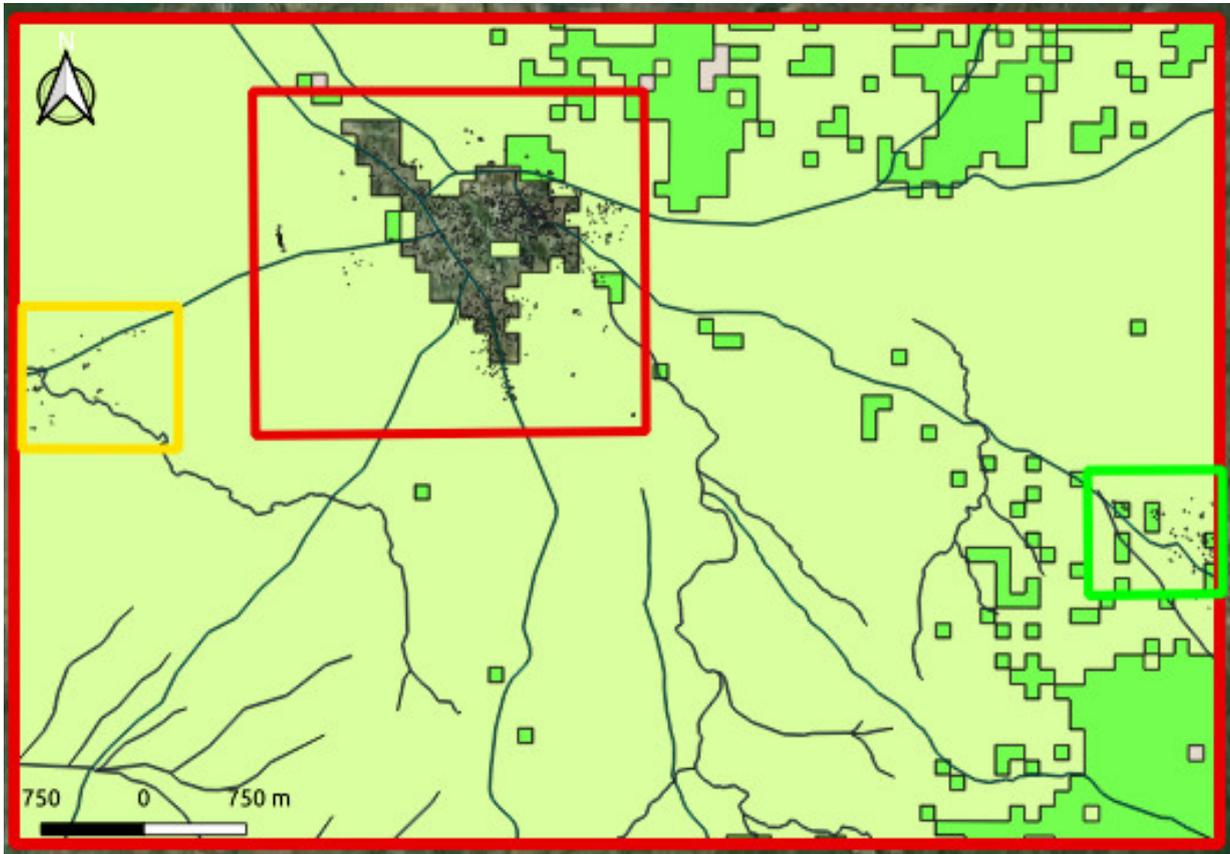
Cette nomenclature doit toutefois être ensuite confrontée à ce qui est réellement distinguable sur les images satellitaires disponibles, afin de dresser conjointement avec les producteurs de la carte une liste des classes qui pourront être reconnues. Cette liste de classes sera **la nomenclature définitive de la carte**. La nomenclature 1) détermine le type d'information que l'on souhaite cartographier, 2) détermine aussi le niveau de précision souhaité pour cette information, 3) liste tous les types possibles sur la zone d'étude au regard de cette information et 4) permet d'établir des groupes d'objets similaires, sur la base de caractéristiques communes au regard de cette information.

Dans le contexte de la classification de l'OCS, une mauvaise information sur le terrain peut être constatée lors de la création de données. Elle est due à une mauvaise saison occasionnant une dynamique de certaines classes et/ou un manque d'expérience de l'opérateur. Par exemple, un opérateur ne pourra pas distinguer au mois de décembre (saison sèche) les routes (RTE) qui se confondent aux rivières (RIV) sur la zone d'étude Nord. De plus, les classes d'OCS à discriminer peuvent être très complexes et les spécifications (définitions) des classes d'OCS peuvent être ambiguës. Par exemple, la végétation nue et clairsemée (VNC) et la végétation herbacée (VHB) sont deux classes de végétation très similaires, difficiles à discriminer sur le terrain et encore plus à partir d'images aériennes ou satellitaires. Des erreurs informatiques et humaines peuvent aussi causer la modification de l'étiquette. Par ailleurs, la combinaison de données pas à jour est parfois nécessaire même si cette combinaison peut engendrer la présence de données mal étiquetées, les désaccords entre les BDs et les hétérogénéités spatiales affectant la précision des étiquettes référencées.

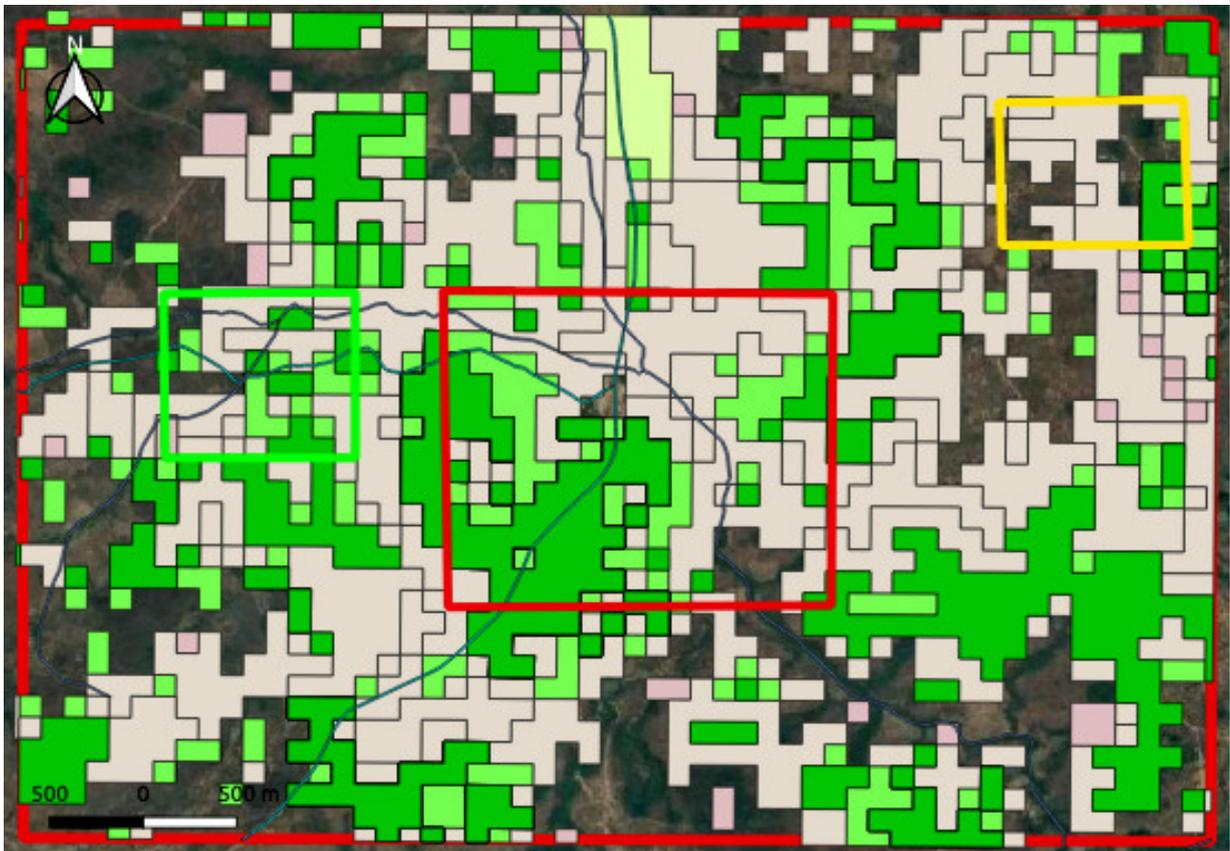
Malgré la définition des classes d'OCS correspondant aux nomenclatures hiérarchiques proposées dans le Tableau 3.6, il a toujours manqué de données de référence au cours de ces travaux. Ainsi, la Figure 4.5 montre l'insuffisance de données de référence avec le déséquilibre réel qui existe entre les différentes classes utilisées pour la classification de l'OCS. La Figure 4.5A montre par exemple les très faibles pourcentages des données vecteurs des classes RTE et BTM sur la zone urbaine de la zone Nord. De faibles pourcentages des données vecteurs des classes VNC, VHB et FFE y sont aussi visibles sur la zone rurale de même que des classes SFE, ZHU et RIV sur la zone de petites classes locales de la zone d'intérêt *T33PUL*.

L'une des raisons du manque de données de référence est due au fait que la collecte de ces données est une tâche difficile qui ne peut s'effectuer aisément qu'en période de ciel clair pendant la saison sèche comme c'est le cas sur la zone Ouest-Centre entre les mois de janvier et mars ou alors d'octobre et décembre dans l'exemple de la Figure 4.5B. Dans cet exemple, de faibles pourcentages des données vecteurs de toutes les classes ont également été utilisés sur les zones urbaine, rurale et de petites classes locales de la zone Ouest-Centre.

L'objectif étant d'établir la classification de l'OCS à l'échelle des données de type Sentinel-2, à des fins de reproductibilité dans le temps et d'étendue dans l'espace, certaines classes d'OCS ne pouvant pas être discernées les unes des autres ont été fusionnées sous le même type d'OCS dans le Tableau 3.6, afin de trouver un compromis entre classes nécessaires pour décrire l'OCS (classes « détectables ») à partir des données de télédétection considérées et des informations disponibles dans les BDs existantes. Dans la suite, seule la problématique du manque de données de référence satisfaisantes est abordée.



(A) Extrait de la zone d'intérêt T33PUL



(B) Extrait de la zone d'intérêt T32NPL

FIG. 4.5 – Illustration de l'insuffisance de données de référence pour la légende à 12 classes sur les zones d'intérêt. Les zones rurale et urbaine et de petites classes locales étant respectivement représentées par les polygones rectangulaires *vert* et *rouge* et *jaune*.

4.3.2 Données de référence insuffisantes : Incomplétude et décalage

L'utilisation de données de référence insuffisantes pour l'apprentissage est connue pour avoir des conséquences sur les performances de l'algorithme de classification supervisée, en particulier sur la qualité des cartes d'OCS obtenues. Afin de réduire la sensibilité de l'algorithme de classification au manque de données de référence et d'améliorer ainsi la qualité des différentes classifications produites, une solution proposée est d'augmenter la taille de la zone d'entraînement afin d'accroître la probabilité de détecter une éventuelle corrélation entre les données de référence et les images satellitaires.

Les données utilisées en entrée des systèmes de classification peuvent être insuffisantes impactant ainsi la précision du vecteur de variables qui décrit les échantillons d'apprentissage. Alors que la grande majorité des études de production d'OCS par télédétection utilisent les systèmes de classification des types de physionomie, la classification détaillée d'un territoire est beaucoup plus difficile à entreprendre puisqu'une énorme quantité de données est nécessaire. (LUCAS et al., 2007b; LUCAS et al., 2011) ont été les premiers à développer une approche à base de règles pour générer une carte détaillée des habitats à l'échelle du Pays de Galles. La correspondance entre les classes physionomiques et les types d'habitats est loin d'être simple. Pour établir un lien entre ces deux niveaux d'observation, une bonne cohérence doit être établie entre les informations de terrain et l'interprétation experte par télédétection. L'étalonnage des classifications supervisées d'images et des modèles à base de règles est une étape essentielle pour extraire de l'information utile sur les habitats à partir des données de télédétection. Traditionnellement, l'étalonnage de tout algorithme de classification par télédétection doit s'appuyer sur des échantillons de terrain (**sites d'entraînement**) qui correspondent à des zones spectralement homogènes de la classe d'intérêt. Cependant, les relevés sur le terrain nécessaires pour calibrer certaines classifications peuvent être extrêmement coûteux. Par exemple, 1325 parcelles homogènes soigneusement sélectionnées ont été nécessaires pour classer une mosaïque de 6 images hyperspectrales aéroportées en huit classes d'habitats différents (HAEST et al., 2010).

Dans certains cas, les approches par classification non supervisée pourraient être exécutées dans une première étape et utilisées comme un outil pour explorer le contenu de l'information spectrale d'une image et donc pour guider le travail sur le terrain. Un échantillonnage bien conçu spécifiquement dans le but de créer des sites d'entraînement pour la télédétection est beaucoup plus efficace que toute récupération de description de terrain qui n'était pas destinée à cet objectif. Tout suivi des changements par télédétection, que ce soit pour suivre la phénologie ou l'évolution des classes d'OCS, doit être accompagné d'un échantillonnage temporel adapté au terrain. Dans ce cas, il est recommandé d'établir des zones d'échantillonnage permanentes.

L'intégration des données de référence et de télédétection est également traditionnellement appliquée pour la validation des cartes réalisées automatiquement. Le but de la validation est d'établir si la représentation des classes d'OCS données par la télédétection est en accord avec les données collectées sur le terrain. Un cadre spécifique de validation de la qualité des informations issues de la télédétection devrait être mis en place systématiquement afin d'évaluer non seulement la précision classique mais également la conformité à d'autres exigences telles que l'aptitude à l'usage prévu, la reproductibilité du résultat obtenu, la transférabilité à d'autres contextes, une comparaison des coûts associés (BORRE et al., 2011).

Quel que soit le but et le niveau d'intégration des données de référence et de télédétection, la compatibilité des échelles doit être examinée avec attention. Trouver une concordance parfaite entre

les images de télédétection et les polygones des différentes classes d'OCS de la vérité terrain (VT) est difficile. De toute évidence, les pixels doivent être plus petits que les polygones de la VT pour une calibration et une validation appropriées des données de télédétection. Néanmoins, comme indiqué précédemment, lorsque les pixels ont une très haute résolution spatiale (**de l'ordre du mètre**), les ombres créent une plus grande hétérogénéité spatiale dans les réponses spectrales créant plus de bruits que d'informations utiles. D'autre part, une plus faible résolution spatiale peut limiter la capacité de détecter de petites variations dans les types de classes d'OCS à cause des processus de lissage de l'information qui peuvent gêner la détection des variations fines (ROCCHINI et al., 2010a). (TURNER et al., 2003) ont résumé le problème de l'appariement des échelles en déclarant que le défi pour le chercheur est de s'assurer que l'échelle de l'imagerie corresponde à celle de la donnée de référence et que les deux soient envisagées à l'échelle adaptée pour permettre de tester la théorie en question.

Une solution à ce problème réside dans l'analyse multi-échelle qui permettrait d'accroître la probabilité de détecter une éventuelle corrélation entre les données de référence et de télédétection (NAGENDRA, 1999). Limiter les plans d'échantillonnage à un seul niveau d'échelle pourrait cacher des processus importants qui s'opèrent à d'autres échelles. Les plans d'échantillonnage multi-échelles sont élaborés pour être en mesure de détecter la diversité des habitats aux échelles fines ou grossières (ROCCHINI et al., 2010b). L'échantillonnage des classes à plusieurs échelles spatiales est également important pour appréhender la relation aire/espèces et comprendre les patrons multi-échelles de répartition des différentes classes d'OCS. Bien conçues, les techniques d'approches multi-échelles, qui sont testées pour plusieurs types de classes d'OCS, peuvent avoir de nombreux avantages par rapport aux techniques mono-échelles à un seul objectif couramment utilisées. Pardessus tout, les données collectées grâce à un plan d'échantillonnage multi-échelle peuvent être mieux reliées aux échelles multiples de la télédétection (considérées soit par une série d'images multi-résolution ou par plusieurs niveaux de segmentation d'une seule image) et donc peuvent permettre d'appréhender l'échelle la plus pertinente pour l'intégration de la télédétection aux données de référence.

Bien que certaines études évaluent l'influence de la quantité de données de référence sur les performances de la classification, à notre connaissance, aucune n'a encore été menée dans le contexte de la classification de synthèses mensuelles de séries temporelles d'images Sentinel-2 sur de grandes étendues. L'absence de ces études s'explique par la difficulté d'avoir une importante quantité de données de référence « propre » ou avec une connaissance parfaite des échantillons mal étiquetés (CARLOTTO, 2009).

Ces travaux ne cherchent pas à étudier l'influence du manque de données de référence pour l'apprentissage sur le système de classification notamment sur ses performances mais posent plutôt cette problématique afin d'en tenir compte au moment de tirer des conclusions.

4.4 Présentation des expérimentations

L'objectif général est de comparer différentes stratégies de classification avec différents jeux de données constitués de séries temporelles d'images Sentinel-2 brutes ou leurs différentes synthèses mensuelles avec différentes configurations de BDs de référence (légendes). Dans la première stratégie, les performances de classification de l'algorithme du RF pour différentes légendes sont évaluées et comparées sur l'étendue d'une seule tuile Sentinel-2. Dans la deuxième stratégie, la stabilité de l'algorithme du RF est testée pour chaque légende sur une zone d'étendue plus grande (ZONE1)

induite par l’emprise du groupe de tuiles Sentinel-2 couvrant cette zone d’étude. La troisième stratégie s’intéresse à l’utilisation de synthèse mensuelle de séries temporelles d’images Sentinel-2. Certaines expériences ont porté sur toutes les tuiles individuelles couvrant les deux zones d’étude et d’autres n’ont été menées que sur les deux tuiles individuelles particulières.

Cette section décrit les configurations des différentes études menées en terme d’images satellitaires et de données de référence utilisées. La deuxième partie aborde la question de la stratégie d’échantillonnage visant à partitionner les données de référence en deux sous-ensembles utilisés pour l’apprentissage et l’évaluation. La troisième partie détaille les trois différentes stratégies adoptées, mises en oeuvre et étudiées dans cette thèse. Enfin, la dernière partie est consacrée à la configuration des paramètres de l’algorithme du *RF* étudié.

4.4.1 Images satellitaires et données de référence

Toutes les tuiles qui couvrent les zones d’étude *ZONE1* et *ZONE2* représentées en *bleu* respectivement dans les Figures 3.4 et 3.7, peuvent être utilisées. On considère les deux tuiles particulières *T33PUL* et *T32NPL* au sein de chacune des zones d’étude *ZONE1* et *ZONE2* respectivement. On dispose également d’une série annuelle complète de données Sentinel-1 sur chaque tuile particulière. Elles seront utilisées lors d’expériences dans le Chapitre 5. Des expériences plus poussées adoptant les première et troisième stratégies de classification seront réalisées sur chacune de ces tuiles particulières dans le Chapitre 5.

Les Tableaux A.1, A.3 et A.6 présentent les listes de séries temporelles d’images issues des capteurs Sentinel-1 et Sentinel-2 utilisées sur la zone d’étude *ZONE1* tandis que les Tableaux de A.4 à A.10 présentent les listes de ces séries sur la zone d’étude *ZONE2*. Les acquisitions Sentinel-2 sont peu disponibles sur la zone d’étude *ZONE2* du fait de la présence de nuages et leurs ombres sur cette zone d’étude qui se situe justement dans la partie Ouest-Littoral Cameroun régulièrement couverte de nuages au cours de l’année.

Comme mentionné à la Section 3.3.3, les données de référence utilisées sur les deux zones d’étude sont principalement extraites de trois différentes *BDs* cartographiques : 1) de l’*INC*, 2) de l’*OCS* mondiale (*Global Land Cover*) (*GLC*), et 3) d’*OpenStreetMap* (*OSM*). Ces données de référence sont préalablement fusionnées en trois légendes : 1) *OSM*, 2) *OSM+INC*, et 3) *OSM+INC+GLC* composées respectivement de cinq, neuf et douze classes d’*OCS* comme présenté dans le Tableau 3.8.

Dans ce chapitre, la première zone d’étude (*ZONE1*) est utilisée pour effectuer des études d’impact relatives uniquement à la stratégie d’apprentissage du classifieur *RF* (deuxième stratégie) tandis que les deux zones d’intérêt *T33PUL* et *T32NPL* sont identiquement utilisées pour effectuer des études d’impact relatives à la fois aux données satellitaires et aux légendes à fournir en entrée du classifieur.

4.4.2 Stratégie d’échantillonnage pour l’apprentissage supervisé

En télédétection, il est courant que les données de référence soient composées de polygones représentant des objets homogènes ayant une même *OCS*, *e.g.* une parcelle agricole. Pour s’assurer de l’indépendance des échantillons, la stratégie la plus simple consiste à ne pas utiliser des échantillons test appartenant aux mêmes polygones que les échantillons d’apprentissage.

L’échantillonnage des données de référence consiste à obtenir deux sous-ensembles d’échantillons indépendants utilisés d’une part pour l’apprentissage, et d’autre part pour l’évaluation de l’algorithme

de classification. Un des choix les plus importants concerne le nombre d'échantillons à sélectionner par classe. Cette problématique est complexe. La Section 4.1.1 indique que le nombre d'échantillons d'apprentissage doit être suffisant afin d'éviter la malédiction de la dimension, *e.g.* sélectionner le nombre d'échantillons en suivant la règle des $30p$ avec p la dimension du vecteur de variables.

Dans le contexte de la cartographie de l'OCS, les différentes classes sont rarement représentées de manière équivalente. Une stratégie naïve est de sélectionner le nombre d'échantillons d'apprentissage en suivant la distribution naturelle des classes dans les données de référence, *i.e.* les classes les plus représentées auront un plus grand nombre d'échantillons d'apprentissage. Cependant, certains classifieurs sont sensibles aux problèmes fortement déséquilibrés, *i.e.* le classifieur prédit seulement la classe majoritaire (MENARDI et TORELLI, 2014; SUN, WONG et KAMEL, 2009). L'étude de (KHOSHGOFTAAR, GOLAWALA et HULSE, 2007) montre que cette sensibilité diffère en fonction des classifieurs considérés. Par exemple, les arbres de décision binaires sont peu performants. Les classes minoritaires seront moins présentes dans les noeuds terminaux. Si le vote majoritaire est utilisé, la classe minoritaire aura peu de chance de l'emporter.

Afin de remédier à ces problèmes, des stratégies de sur- et de sous-échantillonnage ont été proposées dans la littérature (CHAWLA, Springer, 2005; ESTABROOKS, JO et JAPKOWICZ, 2004). Spécifiquement pour l'algorithme du RF, deux solutions pour travailler sur les problèmes déséquilibrés ont été proposées : 1) sélectionner le même nombre d'échantillons par classe, et 2) donner plus d'importance aux classes minoritaires en pondérant le critère de Gini et le vote des noeuds terminaux (CHEN, LIAW et BREIMAN, 2004; THOMAS, JOUVE et NICOLOYANNIS, 2006). (MELLOR et al., 2015) montrent aussi que déséquilibrer le problème en faveur des classes les plus difficiles peut améliorer les résultats de la classification. Malheureusement, les classes les plus difficiles sont généralement aussi les moins représentées. Au contraire, (COLDITZ, 2015) recommande d'utiliser un nombre d'échantillons par classe par rapport à la proportion des classes sur le terrain. Cette directive peut être difficile à appliquer si les données de référence sont incomplètes ou trop anciennes, car la distribution des échantillons par classe est alors biaisée, et non représentative de la réalité. Les recommandations de (WEISS et PROVOST, 2015), bien que plus nuancées, sont aussi de privilégier la distribution naturelle des données. Cependant, les auteurs montrent que choisir le même nombre d'échantillons par classe peut être favorable aux arbres de décision binaire.

Les résultats concernant le nombre d'échantillons d'apprentissage par classe à sélectionner sont donc divergents. Dans les travaux de cette thèse, cette problématique n'a pas été spécifiquement abordée. Il a été choisi de favoriser des problèmes équilibrés à l'apprentissage d'une part pour ne pas désavantager l'algorithme du RF sensible aux problèmes déséquilibrés (AKBANI, KWEK et JAPKOWICZ, 2004; MELLOR et al., 2015), et d'autre part pour ne pas donner d'a priori à la distribution des classes.

La même problématique se pose pour les échantillons test car les mesures de performance globales comme l'OA, sont influencées par un nombre d'échantillons déséquilibrés (Section 2.6). Cependant, les performances sont évaluées ici sur l'ensemble des échantillons test disponibles afin de prendre en compte la distribution naturelle des classes (CONGALTON et GREEN, 2008). Les échantillons d'apprentissage, de test et d'évaluation sont extraits pour chacune des deux tuiles particulières couvrant entièrement les deux zones d'intérêt. On s'intéresse surtout au F-Score_moyen (FS) qui est plus intéressant que l'OA de ce point de vue.

Au cours des expériences menées, il est possible de créer des échantillons « synthétiques » pour les classes mal représentées. Dans le cadre des travaux de cette thèse, plusieurs valeurs du nombre

d'échantillons d'apprentissage sont testées et la chaîne *iota*² n'a pas donné de résultats pour de grandes valeurs du nombre d'échantillons d'apprentissage. Finalement, le nombre d'échantillons d'apprentissage est fixé à 40 000 échantillons par classe quand c'est possible. L'influence du nombre d'échantillons d'apprentissage n'a pas été analysée dans le cadre des travaux de recherche. Selon les expériences menées, on travaillera soit sur une même tuile, soit sur plusieurs tuiles en apprenant sur certaines pour classifier d'autres et en distinguant à chaque fois les jeux d'apprentissage et de test.

4.4.3 Problématiques et stratégies adoptées

4.4.3.1 Problématiques

Les problématiques traitées portent sur les études d'impact relatives à la **stratégie d'apprentissage (APP)** du classifieur et aux **jeux de données (JDD)** utilisés. Trois études d'impact relatives à la stratégie d'apprentissage du classifieur sont effectuées :

1. **Auto-entraînement (APP1)** : peut-on entraîner sur une tuile et la classifier ?
2. **Transférabilité (APP2)** : peut-on transférer un modèle appris sur une tuile vers une autre ? Dans ce cas, obtient-on un résultat similaire à celui d'un auto-entraînement ?
3. **Stabilité (APP3)** : un apprentissage effectué sur un bloc constitué de plusieurs tuiles apporte-il plus de stabilité et améliore-t-il plus les résultats ? Dans ce cas, quel résultat obtient-on en augmentant la taille de la zone d'entraînement (bloc de tuiles d'entraînement) ?

Trois études d'impact relatives aux jeux de données sont également réalisées :

1. **Influence de la nomenclature (JDD1)** : quel résultat obtient-on en fusionnant davantage de sources (configurations de BDs) avec des classes plus riches pour constituer les données de référence ?
2. **Influence de la dimension temporelle (JDD2)** de séries d'images Sentinel-2 : quel est l'intérêt d'effectuer la classification de l'année complète plutôt que des classifications par mois ? Est-ce en raison du fait d'avoir à traiter une série temporelle plus dense et donc d'améliorer le *gapfilling* à partir de toutes les données dans la classification annuelle ? Dans ce cas, quel pas temporel améliore les résultats ?
3. **Utilisation de synthèses mensuelles (JDD3)** de séries d'images Sentinel-2 (cf. données L3A) et **sensibilité aux périodes** : quelle période de synthèse mensuelle de séries temporelles d'images optiques Sentinel-2 améliore le plus les performances de la classification ?

4.4.3.2 Stratégies adoptées

Afin de répondre aux différentes problématiques listées ci-dessus, trois **stratégies (STR)** de classification de l'OCS sont considérées :

La **première stratégie (STR1)** consiste à **utiliser le jeu de données** constitué de séries temporelles **uniquement d'images optiques Sentinel-2 de niveau 2A (Level 2A (L2A))**. Des classifications sont calculées sur deux périodes (mensuelle et annuelle) de classification c'est-à-dire :

- pour **chacun des 12 mois** de janvier à décembre (**STR12A**),
- pour l'ensemble des 12 mois constituant l'**année complète 2018 (STR12B)**.

La **deuxième stratégie (STR2)** consiste à entraîner le classifieur sur une partie représentée par un bloc de tuiles Sentinel-2 sur la zone d'étude et tester ensuite le modèle d'entraînement obtenu sur toute l'étendue de cette zone d'étude. Plus précisément, cette approche consiste, afin d'évaluer la stabilité du classifieur, à **appliquer les différents modèles obtenus en ajoutant chaque fois une tuile au précédent bloc pour augmenter ainsi progressivement la taille de la zone d'entraînement**. Comme pour la première stratégie, on utilise le jeu de données constitué de séries temporelles d'images optiques Sentinel-2_L2A pour des périodes mensuelles et annuelles réparties comme suit :

- pour **chacun des 6 mois** : janvier, mars, mai, juillet, septembre et novembre (**STR22A**),
- pour l'ensemble des 12 mois constituant l'**année complète 2018 (STR22B)**.

La **troisième stratégie (STR3)** consiste à **produire la classification de l'OCS à partir de séries temporelles** comme pour la première stratégie à la différence que l'on utilise cette fois, non plus des images L2A mais plutôt un **jeu de données constitué de synthèses mensuelles de niveau 3A (Level 3A (L3A))** de séries temporelles uniquement d'images optiques Sentinel-2_L3A préalablement générées. Différentes configurations sont considérées à savoir :

- pour **chacune des 10 synthèses mensuelles** février_P45, mars_P45, avril_P45, mai_P45, juin_P45, juillet_P45, août_P45, septembre_P45, octobre_P45 et novembre_P45 qui moyennent indépendamment des séries temporelles sans nuages d'images Sentinel-2 collectées **sur une période de 45 jours (P45)** et centrées sur les mois mentionnés (**STR3(P45)A**),
- pour l'ensemble des 10 synthèses mensuelles de période P45 constituant la **synthèse 2018_P45 (STR3(P45)B)**,
- pour **chacune des 5 synthèses mensuelles** mars_P105, mai_P105, juillet_P105, septembre_P105 et novembre_P105 moyennant des séries temporelles d'images Sentinel-2 collectées **sur une période de 105 jours (P105) (STR3(P105)A)**,
- pour l'ensemble des 5 synthèses mensuelles de période P105 constituant la **synthèse 2018_P105 (STR3(P105)B)**,
- pour **chacune des 3 synthèses mensuelles** avril_P165, juillet_P165 et octobre_P165 moyennant des séries temporelles d'images Sentinel-2 collectées **sur une période de 165 jours (P165) (STR3(P165)A)**,
- pour l'ensemble des 3 synthèses mensuelles de période P165 constituant la **synthèse 2018_P165 (STR3(P165)B)**,
- pour **chacune des 2 synthèses mensuelles** mai_P225 et septembre_P225 moyennant des séries temporelles d'images Sentinel-2 collectées **sur une période de 225 jours (P225) (STR3(P225)A)**,
- pour l'ensemble des 2 synthèses mensuelles de période P225 constituant la **synthèse 2018_P225 (STR3(P225)B)**,
- pour l'**unique synthèse mensuelle** centrée au mois de juin, juin_P315 moyennant des séries temporelles d'images Sentinel-2 collectées **sur une période de 315 jours (P315) (STR3(P315))**.

4.4.4 Configuration des paramètres du RF

Le choix des paramètres du RF n'est pas très sensible au problème du bruit d'étiquetage (PELLETIER et al., 2016). Par conséquent, un seul classifieur RF utilisant toutes les données de référence et les

images disponibles pourrait être entraîné et appliqué sur l'ensemble des zones d'étude. Au cours de l'ensemble des travaux de classification, un nombre de 40 000 échantillons d'apprentissage par classe quand c'est possible, est fixé et la combinaison des paramètres est choisie telle que : 1) $K = 100$, 2) $m = \sqrt{p}$, 3) $max_depth = 25$, et 4) $min_samples = 5$.

4.4.5 Évaluation des résultats

Les données de référence utilisées pour la classification n'en sont pas vraiment, dû au fait qu'elles sont construites à partir de différentes sources de données (BDs) qui sont incomplètes, pas à jour ou trop généralisées. Lors de l'évaluation des résultats, on ne peut pas se contenter de calculer des scores de performance (taux de bonne classification) par rapport à une référence si imparfaite. C'est ainsi qu'en plus de cette évaluation quantitative classique par rapport à ces « pseudo » vérité terrain (VT) (Section 4.3.5.1) et d'une analyse qualitative (visuelle) (Section 4.3.5.2), on peut essayer de **comparer** les résultats entre eux, **pixel à pixel** avec les taux de bonne classification classiques et **par région** avec des comparaisons des distributions de classes découlant de l'idée selon laquelle les résultats de classification peuvent être corrects et semblables mais bruités et que connaître l'OCS au pixel près n'est pas forcément nécessaire pour beaucoup d'applications ne nécessitant qu'une réalité « statistique » e.g. météorologie, détection de changement etc.

4.4.5.1 Évaluation quantitative / Comparaisons

Avant l'analyse qualitative, il est intéressant d'évaluer les métriques de performances en fonction des classes associées aux différentes légendes de classification. Cette évaluation porte sur chaque métrique individuelle, sous l'hypothèse d'équiprobabilité des classes d'OCS. Leur dépendance et corrélation est ensuite estimée par deux études statistiques comparatives des résultats de classification, pour outrepasser la présence des bruits dans les classifications produites et comprendre davantage la répartition et le comportement des différentes classes d'OCS.

Évaluation quantitative

Les classifications sont évaluées, sur la base du nombre de pixels, à partir des taux de Vrais Positifs (VP), de Faux Positifs (FP) et de Faux Négatifs (FN) (CONGALTON, 1991), qui sont combinés afin de calculer la précision utilisateur (PU), la précision producteur (PP) et le F-Score (FS) par classe. Le taux de Faux Positifs (FP) permet de quantifier les pixels issus des données de référence qui ont été classifiés à tort dans d'autres classes. Le taux de Faux Négatifs (FN) permet de quantifier les pixels qui ont été classifiés en une classe donnée mais qui sont en réalité autre chose. L'indice FS, qui correspond à une moyenne harmonique des précisions PU et PP (RIJSBERGEN, 1979; POWERS, 2010b), présente l'avantage de baisser fortement lorsque l'un des paramètres PU ou PP est bas, et d'être majoré lorsque les deux paramètres sont proches tout en étant élevés.

Comparaison pixel à pixel des classifications

Cette comparaison est effectuée entre les différentes classifications mensuelles et annuelle. Pour ce faire, deux métriques classiques : 1) le coefficient Kappa (K) (*Kappa coefficient* (K)) et 2) le F-Score moyen (FS) (*F-Score averaged* (F-Score_moy (FS))) sont calculées au terme de la comparaison pour mesurer l'accord entre deux classifications.

Comparaison par région des distributions de classes des classifications

L'objectif de cette section est de pousser plus loin les études comparatives par pixel en proposant une nouvelle visualisation matricielle qui exploite les matrices de confusion et un encodage de dégradé de couleurs du vert au rouge au fur et à mesure que la différence devient importante entre les distributions de classes au sein de deux classifications de l'OCS. Une comparaison visuelle de ces distributions de classes est alors effectuée pour essayer de mieux appréhender d'éventuelles incertitudes spatiales et du bruit au niveau des pixels. Plus précisément, cette comparaison est effectuée au sein de régions/zones extraites dans chacune des classifications mensuelles et annuelle produites. Pour ce faire, une grande cellule de taille 200 pixels est considérée au sein de chacune de ces classifications afin de pouvoir prendre en compte les classes trop généralisées en raison de leurs géométries grossières telles que les classes issues de la BDs d'OSM. La comparaison est effectuée uniquement dans cette cellule en calculant les distances euclidiennes entre les distributions (histogrammes) de classes au sein de deux classifications en présence.

4.4.5.2 Évaluation qualitative

L'évaluation quantitative, surtout vue la piètre qualité des données de référence, n'est pas en mesure de révéler plusieurs types d'erreurs présentes au sein des cartes d'OCS. Une inspection visuelle est donc importante. Dans ces travaux, on co-visualisera les différentes cartes de classification produites avec des images *THR* (soit issues des *PVA* de l'INC, soit de *Google Earth*) ortho-rectifiées.

4.4.6 Plan d'expérimentations

Différents scénarios ont été testés en adoptant différentes stratégies de classification afin de répondre aux problématiques résumées dans le Tableau 4.2 et portant sur la stratégie d'apprentissage (*APP*) à adopter et les jeux de données (*JDD*) à utiliser. Plus précisément, les stratégies d'apprentissage d'auto-entraînement (*APP1*) et de stabilité (*APP3*) sont testées d'une part et la sensibilité aux périodes de synthèse (mensuelle ou multi-/pluri- mensuelle) (*JDD3*) est analysée d'autre part. Les études d'influences de la nomenclature (*JDD1*) et de la dimension temporelle (*JDD2*) sont réalisées pour chacune des précédentes études d'impact *APP1*, *APP3* et *JDD3*.

L'objectif général est d'évaluer les performances de la classification en adoptant différentes stratégies d'apprentissage du classifieur et en analysant la sensibilité de la classification aux différentes périodes de synthèse. Trois études sont proposées. Dans la première stratégie, l'auto-entraînement du classifieur *RF* en fonction des légendes utilisées (*APP1*) est testé sur l'étendue d'une tuile Sentinel-2 dans la Section 4.5. Dans la deuxième stratégie, la stabilité de l'algorithme de classification en fonction des légendes utilisées (*APP3*) est testée sur les étendues d'une tuile et d'un bloc de tuiles Sentinel-2 dans la Section 4.6. Et dans la troisième stratégie, une analyse de sensibilité de la classification sur les périodes de synthèse (mensuelle ou multi-/pluri- mensuelle) (*JDD3*) est réalisée dans la Section 4.7.

Les zones d'intérêt *T33PUL* (*ZONE1* au Nord) et *T32NPL* (*ZONE2* entre l'Ouest et le Centre) représentatives de paysages et de zones éco-climatiques différents sont identiquement et indépendamment utilisées dans ce chapitre pour précisément effectuer les études d'impact relatives à la stratégie d'apprentissage (*APP*) du classifieur *RF* et aux jeux de données (*JDD*) utilisés.

TAB. 4.2 – Tableau récapitulatif des problématiques et des stratégies d’expérimentation

Problématiques	Études d’impact	Stratégies adoptées	Scénarii expérimentés	
<i>APP</i> Stratégie d’apprentissage	<i>APP1</i> Auto-entraînement	<i>STR1</i> Classification d’images optiques de niveau 2A sur une tuile Sentinel-2.	<i>STR1</i> Classification d’une tuile Sentinel-2 avec un modèle appris sur cette même tuile.	
	<i>APP2</i> Transférabilité	<i>STRX</i> Transfert de modèle appris entre tuiles Sentinel-2 (perspectives).	<i>STRX</i> Transfert du modèle appris sur une tuile vers une autre tuile Sentinel-2 (perspectives).	
	<i>APP3</i> Stabilité	<i>STR2</i> Application de modèles appris en augmentant la taille de la zone d’entraînement.	<i>STR2A</i> Entraînement sur 3 tuiles. <i>STR2B</i> Entraînement sur 4 tuiles. <i>STR2C</i> Entraînement sur 5 tuiles. <i>STR2D</i> Entraînement sur 6 tuiles.	
<i>JDD</i> Jeux de données	<i>JDD1</i> Influence de la nomenclature	<i>STR11</i> Classification d’images optiques 2A avec 5, 9 et 12 classes sur une tuile Sentinel-2.	<i>STR11A</i> Avec la légende à 5 classes. <i>STR11B</i> Avec la légende à 9 classes. <i>STR11C</i> Avec la légende à 12 classes d’OCS.	
		<i>STR21</i> Classification d’images optiques 2A avec 5, 9 et 12 classes sur un bloc de tuiles S-2.	<i>STR21A</i> Avec la légende à 5 classes. <i>STR21B</i> Avec la légende à 9 classes. <i>STR21C</i> Avec la légende à 12 classes d’OCS.	
		<i>STR31</i> Classification de synthèses mensuelles 3A avec 5, 9 et 12 classes sur une tuile Sentinel-2.	<i>STR31A</i> Avec la légende à 5 classes. <i>STR31B</i> Avec la légende à 9 classes. <i>STR31C</i> Avec la légende à 12 classes d’OCS.	
		<i>JDD2</i> Influence de la dimension temporelle	<i>STR12</i> Classifications mensuelles et annuelle d’images optiques 2A sur une tuile Sentinel-2.	<i>STR12A</i> Pour chacun des 12 mois de janvier à décembre. <i>STR12B</i> Pour l’ensemble des 12 mois constituant l’année complète 2018.
			<i>STR22</i> Classifications mensuelles et annuelle d’images optiques 2A sur un bloc de tuiles S-2.	<i>STR22A</i> Pour chacun des 6 mois : jan., mars, mai, juil., sep. et nov. <i>STR22B</i> Pour l’ensemble des 12 mois constituant l’année complète 2018.
			<i>JDD3</i> Sensibilité aux périodes de synthèse (mensuelle ou multi-/pluri- mensuelle)	<i>STR3</i> Classification de synthèses mensuelles de niveau 3A générées à différentes périodes sur une tuile Sentinel-2.
	<i>STR3(P105)A</i> Pour chacune des 5 synthèses mensuelles sur 105 jours. <i>STR3(P105)B</i> Pour l’ensemble des 5 synthèses sur 105 jours, 2018_P105.			
	<i>STR3(P165)A</i> Pour chacune des 3 synthèses mensuelles sur 165 jours. <i>STR3(P165)B</i> Pour l’ensemble des 3 synthèses sur 165 jours, 2018_P165.			
	<i>STR3(P225)A</i> Pour chacune des 2 synthèses mensuelles sur 225 jours. <i>STR3(P225)B</i> Pour l’ensemble des 2 synthèses sur 225 jours, 2018_P225.			
	<i>STR3(P315)</i> Pour l’unique synthèse sur 315 jours, 2018_P315.			

4.5 Auto-entraînement sur l'étendue d'une tuile Sentinel-2

L'objectif de cette section est de mettre en oeuvre la première stratégie (*STR1*) (Tableau 4.2) qui consiste à entraîner puis appliquer un classifieur *RF* sur une même tuile (zone d'intérêt) de la zone d'étude. On cherche à évaluer l'adéquation des données (images et vérité terrain (*VT*)) à l'extraction des classes d'OCS des différentes légendes considérées. On cherche aussi à étudier s'il est nécessaire de considérer une année complète de données pour la classification ou s'il est possible de se limiter à certaines périodes (mois) de l'année.

Les résultats des classifications supervisées d'OCS des deux zones d'intérêt *T33PUL* et *T32NPL* sont analysés pour les différentes légendes. L'apport des images satellitaires et en particulier de leur dimension temporelle dans la cartographie de l'OCS est analysé au travers des critères de qualité des classifications. Au cours des travaux, toutes les métriques de performances de classification sont calculées en une seule exécution utilisant les mêmes ensembles d'apprentissage et de validation (d'environ 2 millions de pixels chacun).

Avant d'analyser qualitativement les classifications produites, il est intéressant d'évaluer les métriques de performances en fonction des classes d'OCS associées aux différentes légendes. Même si les données de référence sont de piètre qualité, se comparer à elles permet tout de même de traduire une certaine tendance (même si les chiffres sont faibles). Enfin, l'influence de la nomenclature des données de référence et de la dimension temporelle des images satellitaires sur ces performances de classification, est étudiée pour chaque légende.

4.5.1 Zone d'intérêt *T33PUL* (*ZONE1*, Nord)

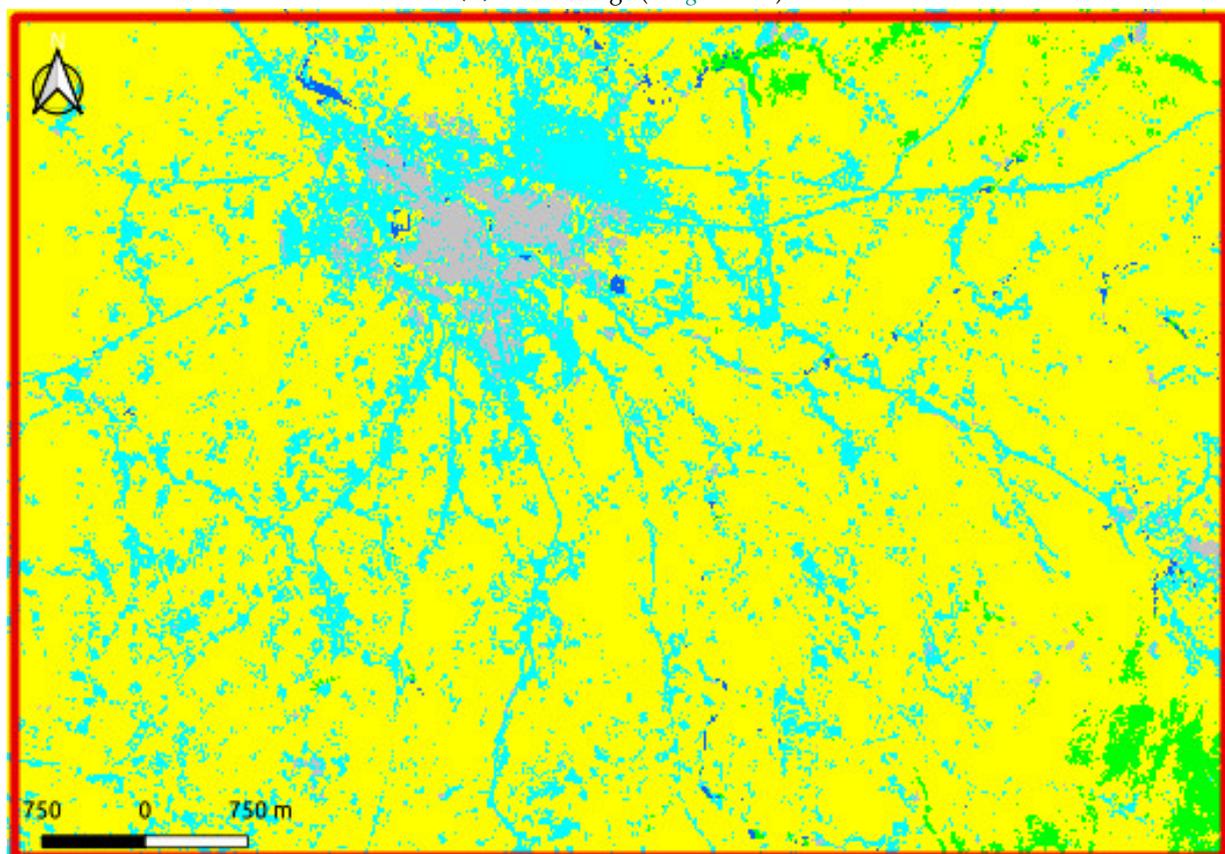
Les extraits d'ortho-image et des classifications supervisées de séries temporelles d'images optiques Sentinel-2_L2A de l'année complète 2018 produites pour les légendes à 5, 9 et 12 classes, de la zone d'intérêt *T33PUL* sont présentées dans les Figures 4.6B, 4.7A et 4.7B respectivement.

4.5.1.1 Evaluation quantitative des classifications supervisées de la zone d'intérêt *T33PUL*

Les Figures 4.8 et 4.9 présentent respectivement les métriques globales de qualité - F-Scores moyens (FS) et coefficients Kappa (K) des classifications supervisées de séries temporelles d'images optiques Sentinel-2_L2A des mois et de l'année complète 2018 pour les trois légendes à 5, 9 et 12 classes. Quelle que soit la légende utilisée dans les classifications, les valeurs de FS et de K pour les images optiques sont variables et faibles ($0,27 < FS < 0,36$ et $0,23 < K < 0,25$). **Les résultats les plus forts sont associés aux classifications de l'année complète pour les légendes à 5 et 9 classes et du mois de mars pour la légende à 12 classes si l'on considère les FS si l'on considère les K et aux classifications des mois de mars, décembre et de l'année complète pour les trois légendes si l'on considère les K. De plus, les classes sont assez déséquilibrées, d'où un K ne reflétant pas certains problèmes.** Au contraire, les résultats les plus faibles sont associés aux classifications du mois d'août pour les trois légendes à la fois du point de vue des FS et des K. Ces résultats sont en accord avec ceux obtenus dans la littérature, qui montrent les limitations des images optiques pour la cartographie des classes végétation nue et clairsemée (VNC) et végétation herbacée (VHB) ainsi que des classes forêt ouverte (FOU) et forêt fermée (FFE) avec la légende à 12 classes qui se trouvent mieux discriminées pendant la saison sèche comme c'est le cas dans les classifications des mois de mars et septembre.

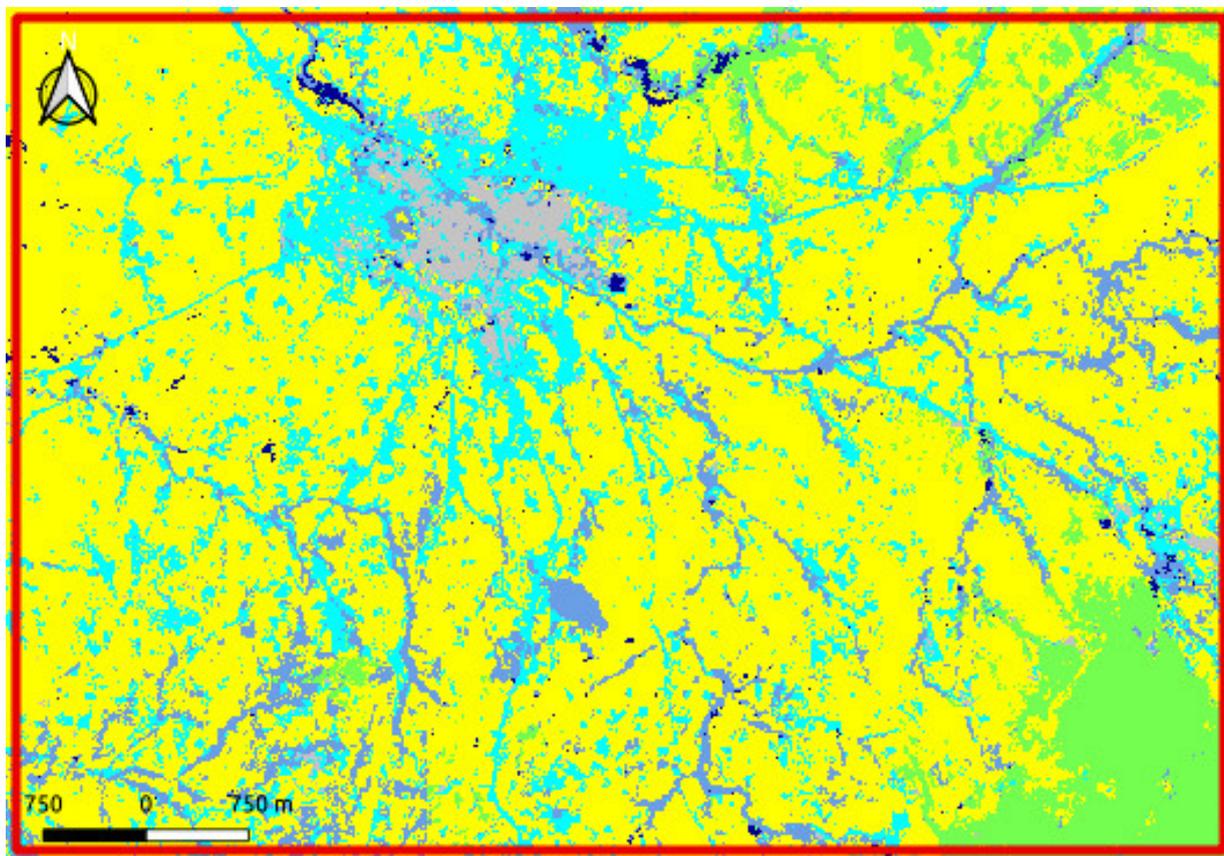


(A) Ortho-image (Google Earth)

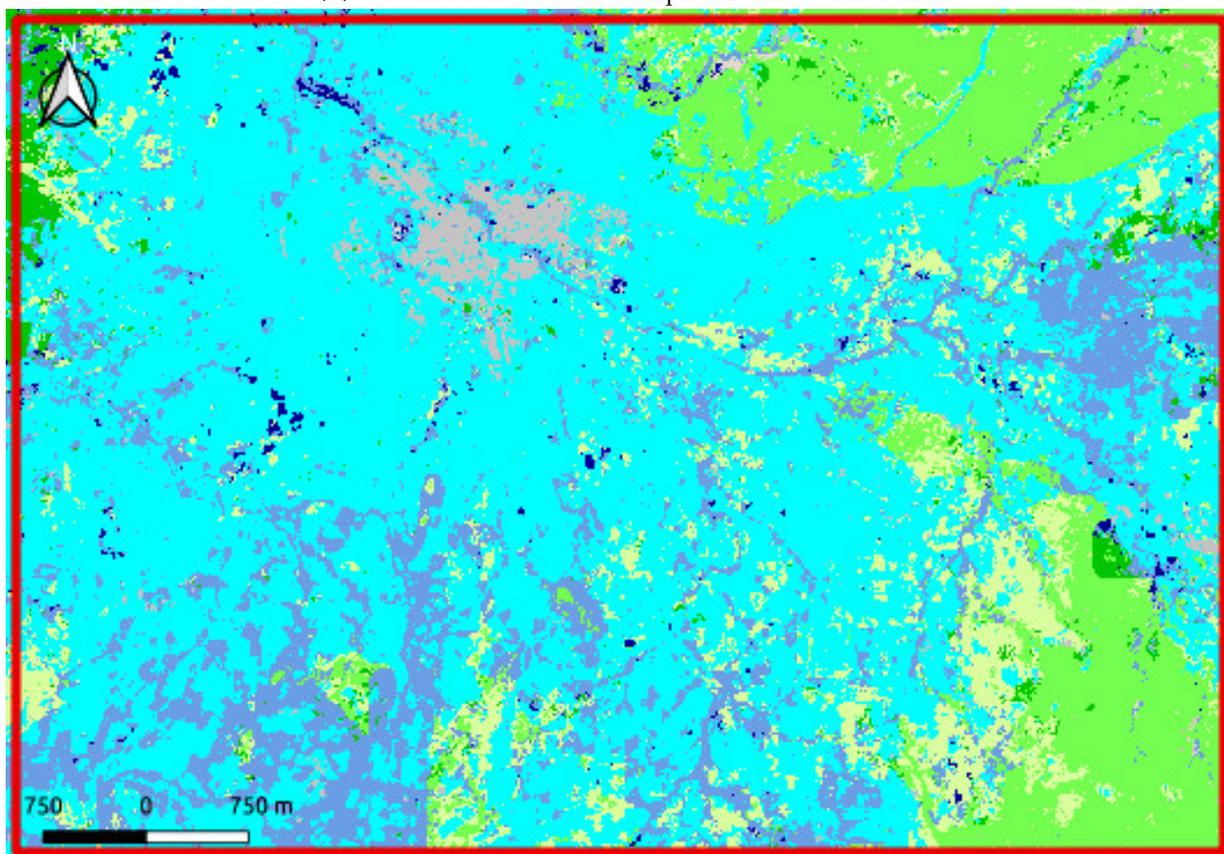


(B) Classification de l'année complète 2018 avec 5 classes

FIG. 4.6 – Extraits de l'ortho-image et de la classification supervisée de séries temporelles d'images optiques Sentinel-2_L2A avec la légende à 5 : ■ : VGT ; ■ : AGR ; ■ : EAU ; ■ : RTE ; ■ : BTM classes, de la zone d'intérêt T33PUL.



(A) Classification de l'année complète 2018 avec 9 classes



(B) Classification de l'année complète 2018 avec 12 classes

FIG. 4.7 – Extraits des classifications supervisées d'images Sentinel-2_L2A avec les légendes à 9 : ■ : FRT; ■ : PRA; ■ : ARB; ■ : AGR; ■ : SFE; ■ : ZHU; ■ : RIV; ■ : RTE; ■ : BTM et 12 : ■ : VNC; ■ : VHB; ■ : FOU; ■ : FFE; ■ : TCU; ■ : ARB; ■ : ZHH; ■ : SFE; ■ : ZHU; ■ : RIV; ■ : RTE; ■ : BTM classes, de la zone d'intérêt T33PUL.

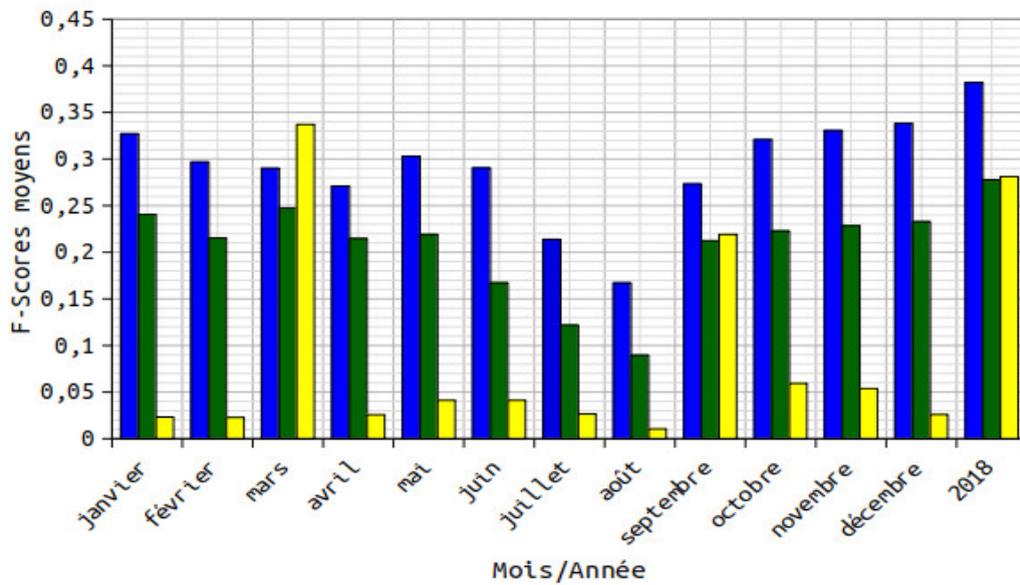


FIG. 4.8 – F-Scores moyens des classifications supervisées de séries temporelles d’images optiques Sentinel-2_L2A avec les légendes à 5 : ■ : OSM et 9 : ■ : OSM+INC et 12 : ■ : OSM+INC+GLC classes, de la zone d’intérêt T33PUL.

La Figure 4.10 présente les métriques de qualité par classe des classifications par mois et de l’année complète 2018 pour la légende à 5 classes. L’utilisation de cette légende permet d’améliorer la classification annuelle des classes eau (EAU) ($FS(EAU) \simeq 0,08$); routes (RTE) ($FS(RTE) \simeq 0,19$) et bâtiments (BTM) ($FS(BTM) \simeq 0,53$). De plus, les classes végétation (VGT) ($FS(VGT) \simeq 0,88$) et agriculture (AGR) ($FS(AGR) \simeq 0,53$) sont améliorées dans les classifications des mois d’octobre et décembre pour la légende à 5 classes.

Dans l’optique de comprendre la répartition des confusions entre les différentes classes d’OCS, une évaluation détaillée par paires de ces confusions est nécessaire. Pour cela, les matrices de confusion correspondantes aux classifications produites pour chacune des trois légendes sont exploitées. Les valeurs de ces matrices sont converties en pourcentage du point de vue producteur puis transposées avant d’être examinées. **Les confusions sont quantifiées à l’aide des taux de Faux Positifs et de Faux Négatifs. L’analyse des confusions permet de mettre l’accent sur les changements à l’intérieur des légendes ainsi que d’une légende à l’autre pour certaines classes d’OCS.** Ainsi, les Tableaux 4.3, 4.4 et 4.5 présentent les matrices de confusion du point de vue producteur des classifications de l’année complète 2018 à 5, 9 et 12 classes sur la zone d’intérêt T33PUL. Les cellules en vert et rouge correspondent respectivement aux pourcentages de pixels bien et majoritairement mal classifiés. On constate des problèmes majeurs de séparabilité qui s’expliquent par des niveaux de réflectance associés à une importante dispersion du signal satellitaire optique sur les classes d’OCS. Pour toutes les légendes, il existe des confusions récurrentes entre les classes lorsque l’on utilise les données optiques seules.

Dans ces tableaux, les pixels identifiés en classe VGT se trouvent majoritairement classifiés en AGR. Le taux de FP, avec la classe AGR, atteint $FP=38,9\%$ avec l’utilisation d’images optiques Sentinel-2 seules pour la légende à 5 classes (regroupement de classes d’OCS contiguës dans les données de référence). La confusion s’atténue fortement avec l’utilisation des classes FRT; PRA et ARB de la légende à 9 classes fusionnées en classe VGT de la légende à 5 classes, et les taux de FP diminuent à

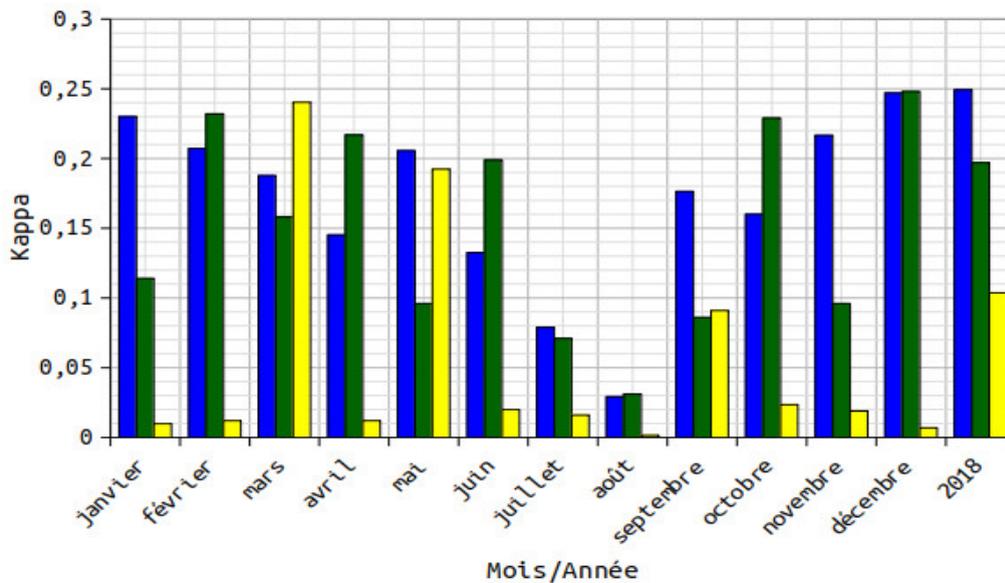


FIG. 4.9 – Coefficients Kappa des mêmes classifications que les FS dans la Figure 4.8.

partir des pixels de la classe ARB majoritairement classifiés en AGR ($FP=17,3\%$) puis ceux de la classe FRT se retrouvant en AGR ($FP=14,5\%$) jusqu'à ceux de la classe PRA se trouvant en AGR ($FP=13\%$). Concernant les confusions avec la classe EAU, les taux de FP sont assez forts ($FP>20\%$), et affectent principalement l'optique. **Les taux de FP sont davantage forts avec l'ajout de nouvelles classes pour la légende à 9 classes, et atteignent leur maximum au niveau des pixels identifiés en classe VNC se trouvant majoritairement classifiés en RIV ($FP=38,3\%$) avec les images optiques, pour la légende à 12 classes. Cette augmentation de FP se fait au détriment des FN , avec une forte diminution de ceux-ci lors de l'utilisation d'images optiques seules.**

Les confusions entre la classe AGR et les classes EAU ou VGT s'expliquent aussi par leur similarité de réflectance durant la période d'acquisition des images optiques. Les confusions issues de la même légende, sont du même ordre de grandeur et s'expliquent par des niveaux équivalents de rétrodiffusion à l'image optique, liés à l'hétérogénéité structurale des classes AGR et VGT. Ces confusions diminuent avec l'utilisation de la légende à 9 classes. Les confusions qui impliquent la classe EAU s'expliquent en optique de la même manière que pour la classe VGT. En effet, **la classe AGR contribuerait moins à la rétrodiffusion du signal, et il y aurait plus d'impact de la structure de l'eau dans les hyperfréquences, pendant la saison de pluies.** Les synthèses mensuelles de séries temporelles d'images optiques Sentinel-2_L3A permettrait de prendre en compte la structure de la classe AGR, et de s'affranchir des confusions entre cette dernière et la classe EAU. La complémentarité entre les synthèses de séries d'images optique et les séries d'images radar permettrait également de s'affranchir des confusions avec les classes EAU ou VGT.

Par ailleurs, pour la légende à 5 classes, la classe RTE est classifiée en AGR avec un taux de $FP=22,3\%$. À l'inverse, la classe AGR est classifiée en RTE avec un taux inférieur de $FN=12,3\%$. Ce taux augmente et devient $FN=16,9\%$ contrairement au taux de FP qui diminue pour devenir $FP=20,6\%$ et la confusion s'atténue donc pour la légende à 9 classes. Plus le nombre de classes d'OCS augmente, plus l'impact de ces classes est conséquent et meilleure est leur discrimination. Ainsi, **le taux de FN augmente avec le nombre de classes à discriminer en utilisant les images optiques Sentinel-2_L2A seules.**

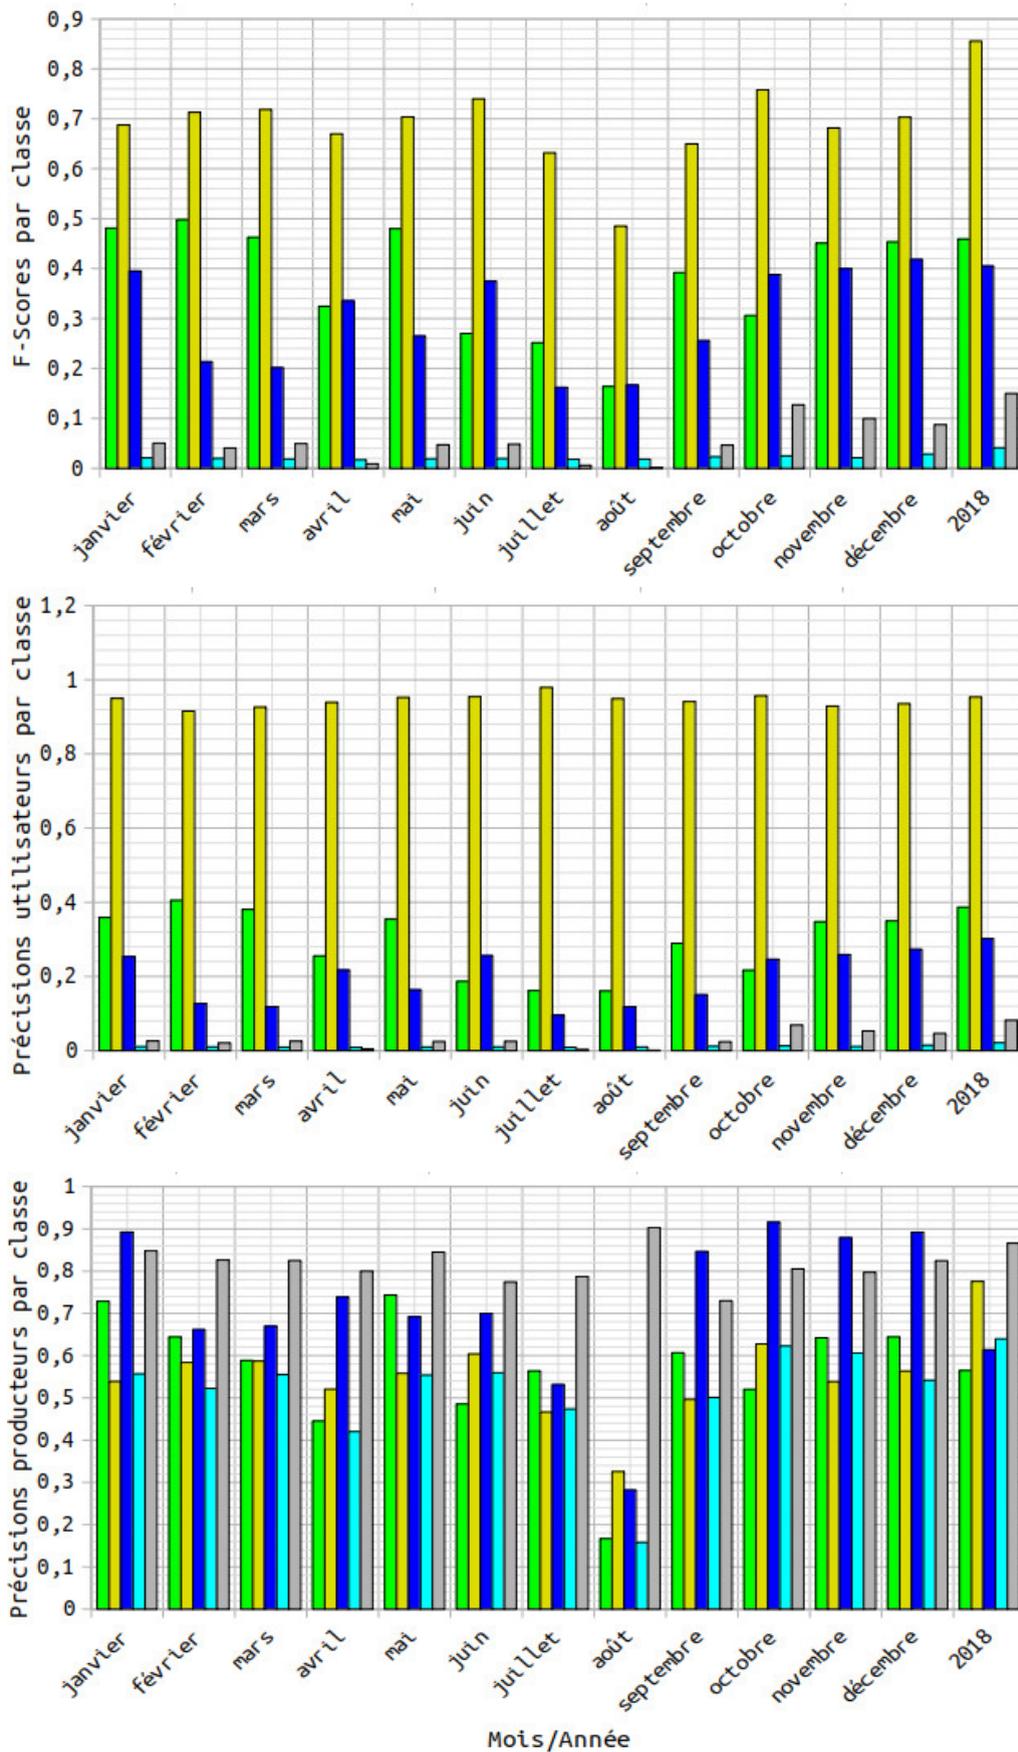


FIG. 4.10 – F-Scores et précision utilisateur et précision producteur par classe des classifications supervisées de séries temporelles d’images optiques Sentinel-2_L2A avec la légende à 5 classes : ■ : VGT; ■ : AGR; ■ : EAU; ■ : RTE; ■ : BTM, de la zone d’intérêt T33PUL.

TAB. 4.3 – Matrice de confusion avec la légende à 5 classes. Après transposition, les colonnes représentent les étiquettes de référence et les lignes représentent les étiquettes produites. Les valeurs sont données en pourcentage de pixels de référence (normalisés par colonne) du point de vue producteur. Les valeurs sur la diagonale et celles à droite représentent respectivement la précision producteur (PP) et la précision utilisateur (PU) de chaque classe.

L2A		Vérité Terrain					PU
% VU	CL	VGT	AGR	EAU	RTE	BTM	
11,8	VGT	56,5	7,4	5,7	2,3	0,3	38,7
77,1	AGR	38,9	77,6	28,3	22,3	3,7	95,3
2,2	EAU	1,2	2,2	61,4	0,5	0,1	30,2
0,1	RTE	3,2	12,3	3,9	63,9	9,4	2,1
0,1	BTM	0,3	0,6	0,7	10,9	86,6	8,2
	PP	56,5	77,6	61,4	63,9	86,6	

TAB. 4.4 – Matrice de confusion avec la légende à 9 classes.

L2A		Vérité Terrain									PU
% VU	CL	FRT	PRA	ARB	AGR	SFE	ZHU	RIV	RTE	BTM	
0,8	FRT	32,4	8,6	2,4	1,1	0,0	1,2	1,8	0,4	0,1	2,2
7,4	PRA	27,7	60,5	6,0	5,6	0,0	0,6	0,3	1,1	0,0	10,7
4,1	ARB	14,6	9,0	49,4	4,5	0,0	1,4	1,5	2,9	0,4	25,8
77,1	AGR	14,5	13,0	17,3	62,9	0,2	27,7	5,1	20,6	3,1	96,8
4,2	SFE	0,3	0,1	0,1	0,1	94,0	2,9	37,0	0,0	0,0	90,4
0,9	ZHU	7,3	2,5	1,6	4,7	3,2	55,6	8,7	1,1	0,2	7,4
0,2	RIV	1,4	3,6	21,3	3,7	2,4	8,3	42,7	3,0	0,7	3,1
0,1	RTE	1,6	2,4	1,7	16,9	0,1	2,0	2,1	61,0	9,7	1,3
0,1	BTM	0,2	0,3	0,2	0,7	0,0	0,2	0,7	10,0	85,8	6,9
	PP	32,4	60,5	49,4	62,9	94,0	55,6	42,7	61,0	85,8	

TAB. 4.5 – Matrice de confusion avec la légende à 12 classes.

L2A		Vérité Terrain											PU	
% VU	CL	VNC	VHB	FOU	FFE	TCU	ARB	ZHH	SFE	ZHU	RIV	RTE		BTM
0,1	VNC	47,8	0,3	0,0	0,0	0,0	0,0	0,8	0,0	0,1	7,8	0,0	0,0	8,0
0,6	VHB	4,5	49,1	3,5	0,4	14,1	6,5	9,4	0,4	32,1	12,9	4,4	0,7	6,4
4,5	FOU	0,0	7,7	49,2	30,2	1,2	20,5	0,7	0,1	3,5	2,4	0,6	0,1	29,3
0,5	FFE	0,0	0,5	24,1	64,0	0,0	1,6	0,1	0,0	0,1	1,3	0,1	0,0	26,6
45,0	TCU	0,0	5,3	3,7	0,3	44,9	29,6	0,6	0,0	3,0	3,6	7,3	1,4	73,1
18,2	ARB	0,1	9,2	13,8	3,8	8,8	31,8	0,6	0,0	2,6	6,4	4,0	0,3	33,7
11,5	ZHH	0,2	3,4	0,2	0,1	0,2	0,1	55,8	2,1	10,4	1,6	0,1	0,0	64,9
4,2	SFE	2,3	1,1	0,5	0,2	0,1	0,1	15,7	95,6	1,6	2,3	0,0	0,0	83,6
0,9	ZHU	6,3	7,7	2,5	0,1	3,6	0,9	7,2	1,1	35,6	6,0	0,6	0,1	7,9
0,2	RIV	38,3	4,8	1,5	1,0	3,5	1,1	8,2	0,4	5,2	48,9	1,9	0,4	3,4
0,1	RTE	0,3	9,6	0,9	0,0	22,2	7,4	0,8	0,1	5,5	6,0	70,8	11,1	0,7
0,1	BTM	0,2	1,3	0,1	0,0	1,3	0,4	0,2	0,0	0,3	0,8	10,4	86,0	4,6
	PP	47,8	49,1	49,2	64,0	44,9	31,8	55,8	95,6	35,6	48,9	70,8	86,0	

% VU : pourcentage de données vecteurs utilisées.

CL : classification.

Les confusions entre les classes AGR et RTE s'expliquent par la diversité de la classe de AGR. Les hétérogénéités de développement des espèces de la classe de AGR entraînent des variations importantes de la valeur de réflectance en optique, à fortiori dans le proche infrarouge, et génèrent des confusions. D'autre part, les routes (RTE) sont très souvent des pistes en sol nu (parfois mal positionnées) tandis que la classe AGR contient aussi de vastes zones de sol nu surtout à la saison sèche. La classe RTE est aussi confondue à la classe RIV du fait de la similarité des RTE avec des lits de

rivière asséchés. Pour s'affranchir de ces confusions, **la complémentarité optique et radar pourrait être exploitée en se fondant sur le principe selon lequel les taux de FP présents en radar et de FN observables en optique disparaissent lors de l'utilisation conjointe des images optique et radar.**

4.5.1.2 Utilisation des confiances des classifications supervisées de la zone d'intérêt T33PUL

Les Figures 4.11A, 4.11B et 4.12 montrent les cartes de confiance correspondantes aux extraits de classifications supervisées de la zone d'intérêt T33PUL dans les Figures 4.6B, 4.7A et 4.7B. Plus le pixel est clair (pas de nuage, pas d'ombre, pas de saturation), plus la confiance est élevée. Eu égard au fait que les valeurs de confiance sont calculées par le classifieur, on peut affirmer qu'elles peuvent ne pas être fiables dans le cas d'une mauvaise classification. Il est donc intéressant d'étudier comment les valeurs de confiance sont liées aux classifications correctes et incorrectes. Aussi, les valeurs de confiance peuvent avoir des distributions différentes pour les pixels ayant servi à l'apprentissage du classifieur, par rapport aux pixels non utilisés pour l'apprentissage.

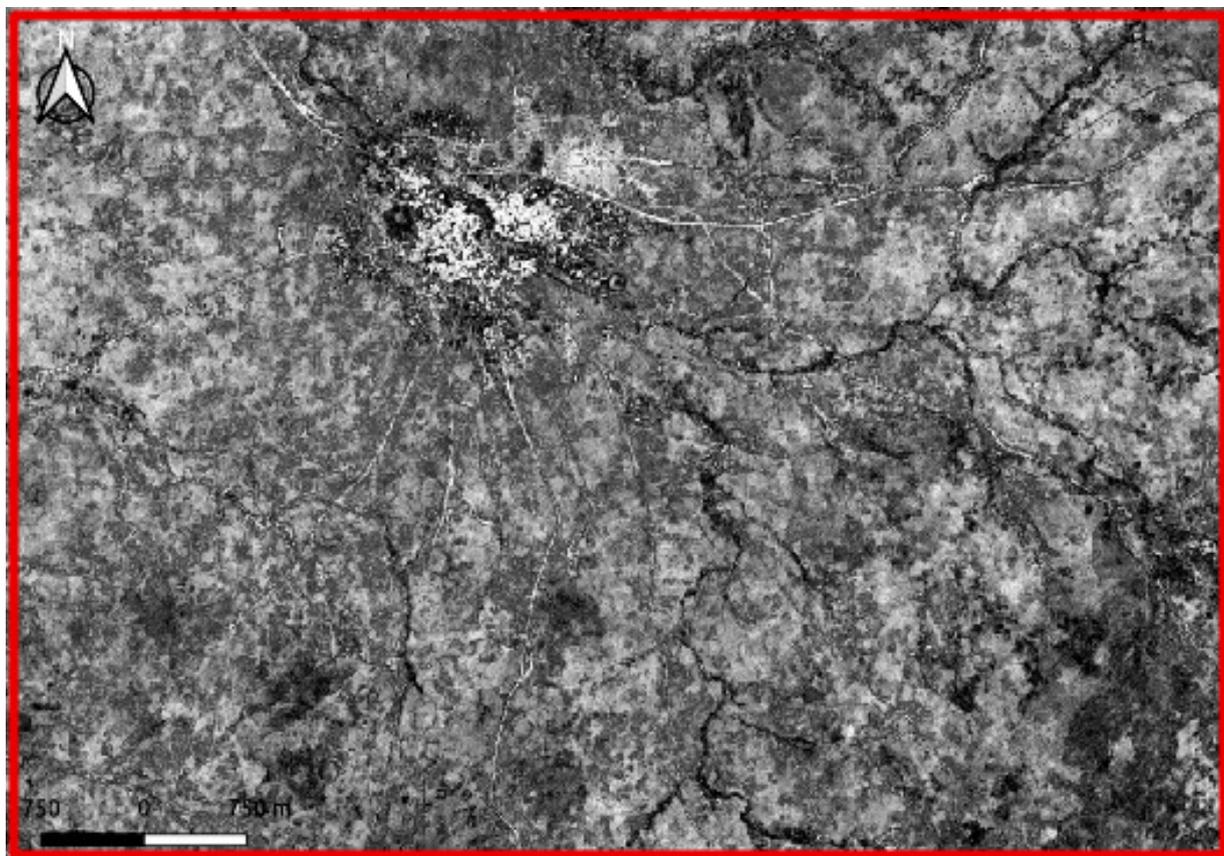
Pour des valeurs de confiance inférieures à 50%, les pixels d'apprentissage et de validation ont des comportements différents. Cela ne permet pas d'utiliser des valeurs de confiance pour faire des déductions sur l'exactitude de l'étiquette donnée par le classifieur. Les pixels d'apprentissage et de validation ont des distributions de confiance similaires pour les valeurs de confiance supérieures à 50%. Selon des études, les échantillons correctement classifiés (apprentissage ou validation) ont une probabilité plus élevée d'avoir des confiances supérieures à 60%. Pour des valeurs de confiance supérieures à 80%, un pixel a 20 fois plus de chances d'être correctement classifié que incorrectement. Par conséquent, la carte de confiance peut être très utile pour l'interprétation de la carte d'OCS.

Étant donné que la confiance est influencée par le nombre de dates pour lesquelles chaque pixel est valide, mais aussi par la légende, on peut observer que **les valeurs de confiance diminuent globalement lorsque le nombre de classes augmente. Par contre, la confiance se trouve renforcée localement lorsque le nombre de classes augmente comme c'est le cas pour les légendes à 9 et 12 classes.** Toutefois, l'effet de la présence de résidus de nuages et leurs ombres sur la zone d'intérêt T33PUL rend les classes d'OCS de la légende à 12 classes difficilement reconnaissables dans la partie sud-est de la Figure 4.12.

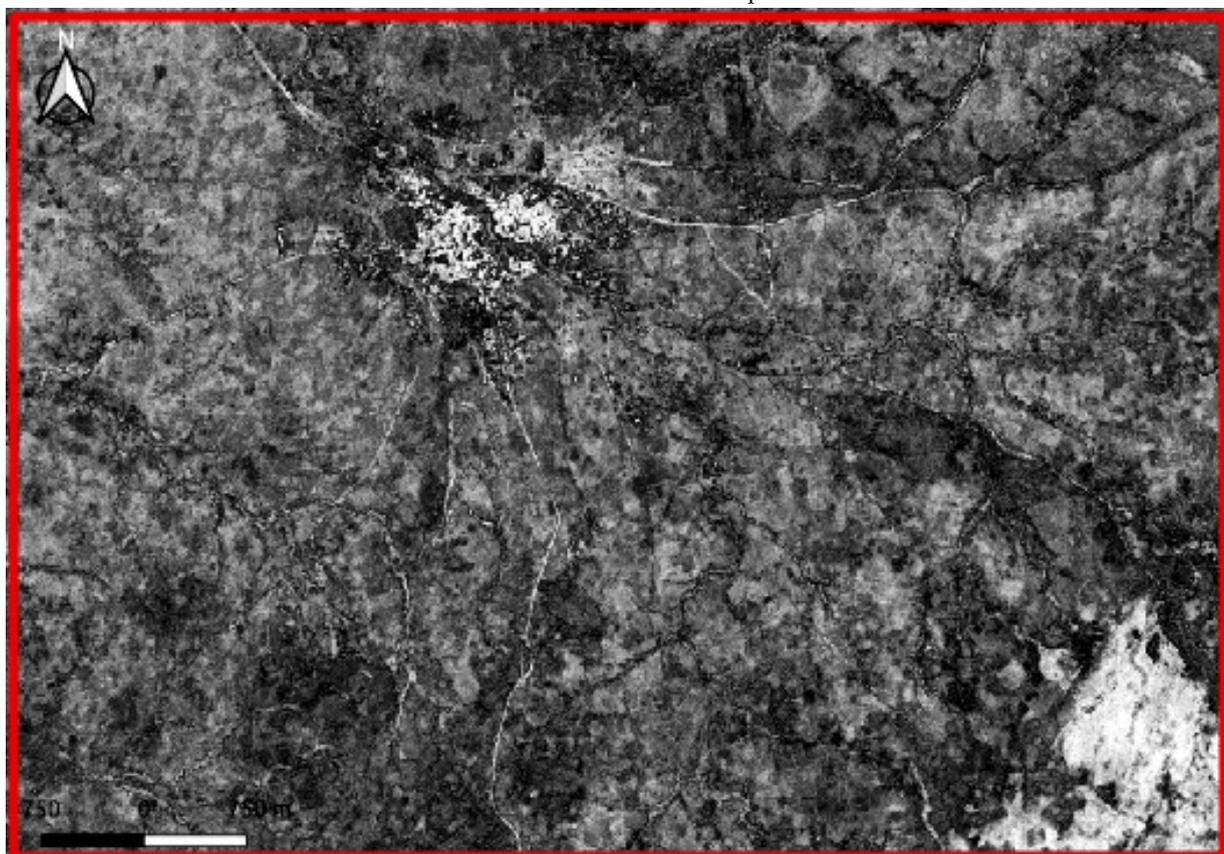
4.5.1.3 Évaluation qualitative des classifications supervisées de la zone d'intérêt T33PUL

Les métriques quantitatives sur une très grande surface ne sont pas en mesure de révéler plusieurs types d'erreurs présentes dans les cartes d'OCS du fait de la qualité de la donnée de référence. Une inspection visuelle permet d'identifier différents problèmes qui sont analysés dans cette section.

4.5.1.3.1 Paysages difficiles dans les classifications supervisées de la zone d'intérêt T33PUL La comparaison des classifications pour les trois légendes permet de mettre en évidence l'avantage de la méthode de classification supervisée sur des zones fragmentées où les régions à topographie irrégulière qui sont beaucoup plus difficiles à cartographier correctement que les zones plates avec de grands paysages homogènes. En effet, les zones de faibles confiances sont réduites tandis que celles de fortes valeurs de confiances sont accentuées. Ceci est dû à la meilleure qualité des classifications supervisées des classes d'OCS pour la légende à 5 classes, ce qui ne ressort pas forcément pour la légende à 12 classes. Ainsi, les résultats de classification sont étudiés en détail sur deux types de zones : **une zone rurale (Figure 4.13) et une zone urbaine (Figure 4.14).**



(A) Confiance de la classification de l'année complète 2018 avec 5 classes



(B) Confiance de la classification de l'année complète 2018 avec 9 classes

FIG. 4.11 – Extraits des confiances de classification supervisée de séries temporelles d'images optiques Sentinel-2_L2A : ■ : faibles → ■ : fortes valeurs, de la zone d'intérêt T33PUL.

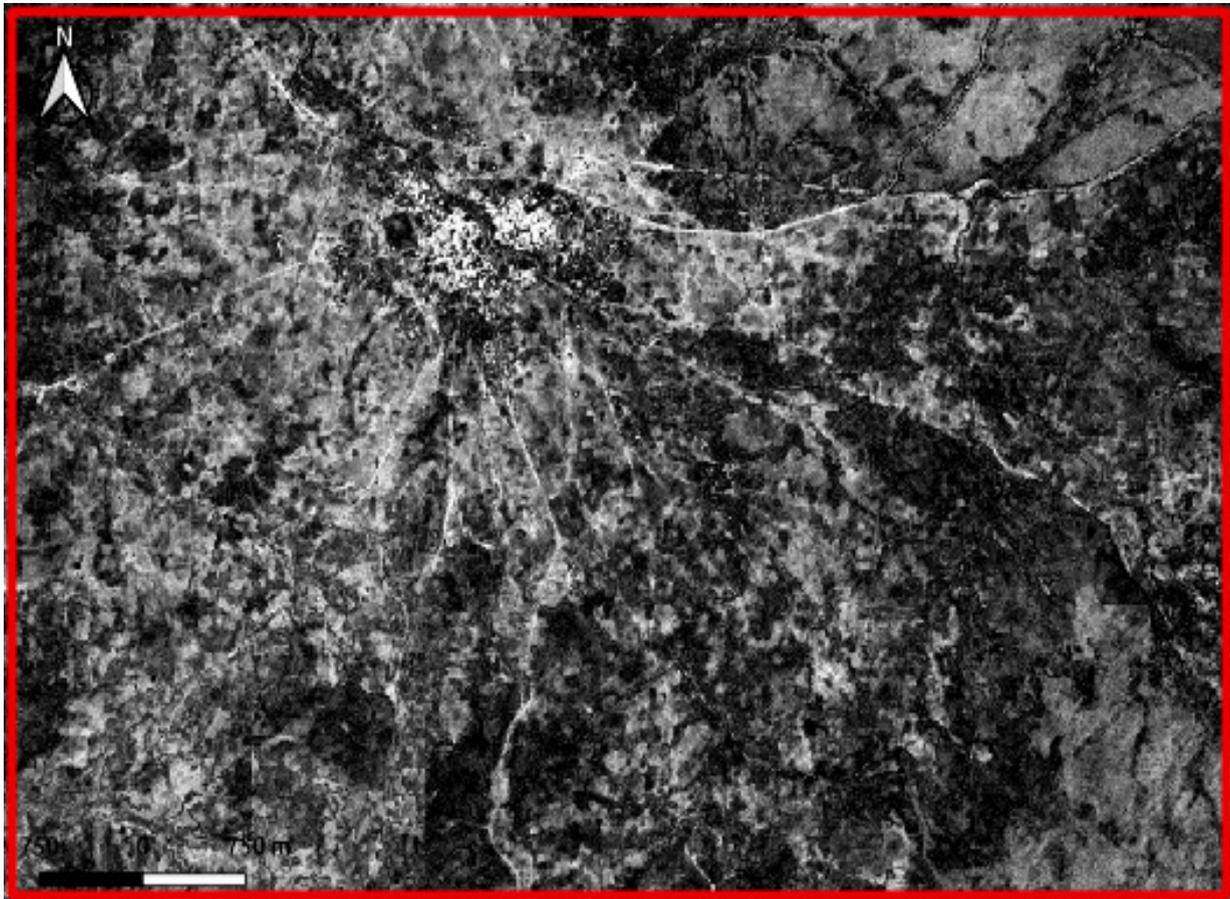


FIG. 4.12 – Extrait de la confiance de la classification supervisée de séries d’images Sentinel-2_L2A avec la légende à 12 classes, de la zone d’intérêt T33PUL.

La zone rurale est majoritairement composée de champs à l’est, de deux rivières qui s’intersectent au nord et traversent l’ortho-image sur un axe nord-sud, d’une zone humide éparse au centre et d’une route au nord (Figure 4.13A). Les différentes classifications et confiances de classification pour les trois légendes sont représentées sur les Figures 4.13B-F. Les classes PRA et ARB ressortent bien pour la légende à 9 classes sur la Figure 4.13C contrairement à la classe VGT qui n’est pas bien détectée pour la légende à 5 classes sur la Figure 4.13B : **la classification permet d’isoler les classes de végétation de manière individuelle, mais elle ne permet pas d’identifier clairement la classe VGT**. On peut noter également un peu de confusion entre les classes ARB et SFE pour la légende à 9 classes sur la Figure 4.13C. Sur cette dernière figure, la classification de la classe RTE est meilleure. En effet, les routes ressortent clairement et précisément, il y a toutefois un peu de confusion avec la classe EAU. De la même manière, les classes FOU et FFE de la légende à 12 classes (Figure 4.13D) sont assez bien représentées. Cependant, mise à part ces cinq classes, les autres posent problème. Par exemple, la classe RIV est confondue presque intégralement avec la classe RTE pour la légende à 9 classes (Figure 4.13C). La classe ZHU contient des zones d’ombres et la classe ZHH fait ressortir la végétation herbacée pour la légende à 12 classes.

La zone urbaine se situe dans le centre-ville de la zone d’intérêt T33PUL. Elle est composée d’habitations resserrées, de rivières et de routes (Figure 4.14B). Pour 5 classes, la classification des classes RTE et BTM (Figure 4.14A) donne de bons résultats permettant de les distinguer avec seulement

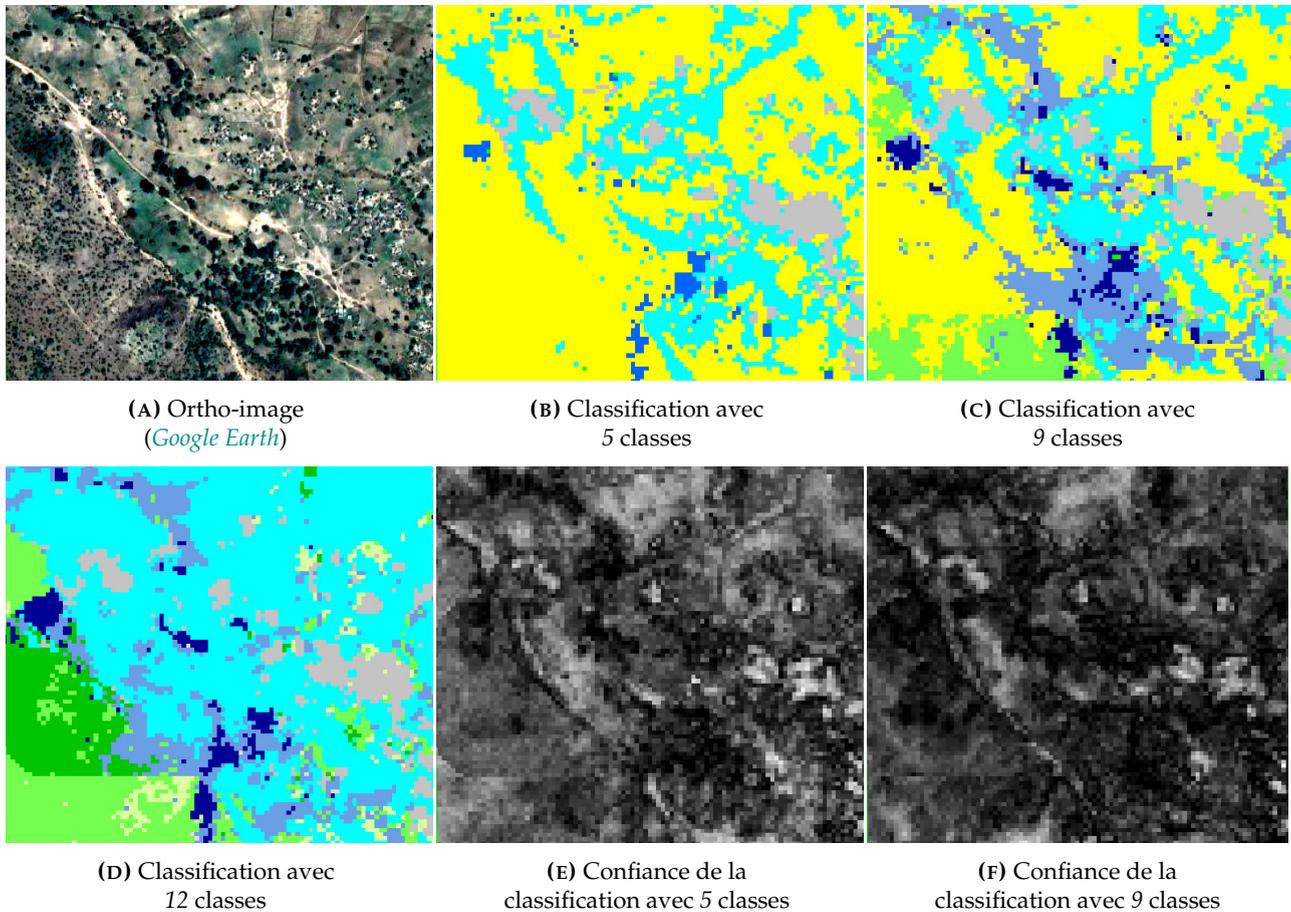


FIG. 4.13 – Extraits de l’ortho-image et des classifications et des confiances de classifications de séries temporelles d’images optiques Sentinel-2_L2A avec les légendes à 5 et 9 et 12 classes, d’une zone rurale sur la zone d’intérêt T33PUL.

quelques confusions apparaissant entre ces classes du fait des zones mixtes que doivent probablement contenir les données d’apprentissage constituées de polygones grossiers qui dégradent la qualité de la classification. Cependant, les classes ZHU et RIV (Figure 4.14C(D)) de la légende à 9 classes (qui sont contenues dans la classe EAU de la légende à 5 classes) sont plutôt mal classifiées, sauf certaines petites zones humides qui se discriminent assez bien de la classe RIV pour la légende à 9 classes. **Cette confusion, que l’on avait déjà observée sur la zone rurale, pourrait être facilement supprimée par exemple en utilisant les synthèses mensuelles Sentinel-2_L3A.**

4.5.1.3.2 Petites classes locales dans les classifications supervisées de la zone d’intérêt T33PUL

Les classes minoritaires sont difficiles à cartographier en raison de leur manque de représentativité lors de l’entraînement. Des exemples typiques sont les classes VNC ; RTE ; BTM ; RIV ; VHB et ZHU. Ces classes sont aussi concentrées dans des régions spécifiques de la zone d’intérêt T33PUL. La Figure 4.15C illustre comment la légende à 12 classes réduit la confusion entre les classes ZHU et RIV.

4.5.1.4 Comparaison pixel à pixel des classifications sur T33PUL

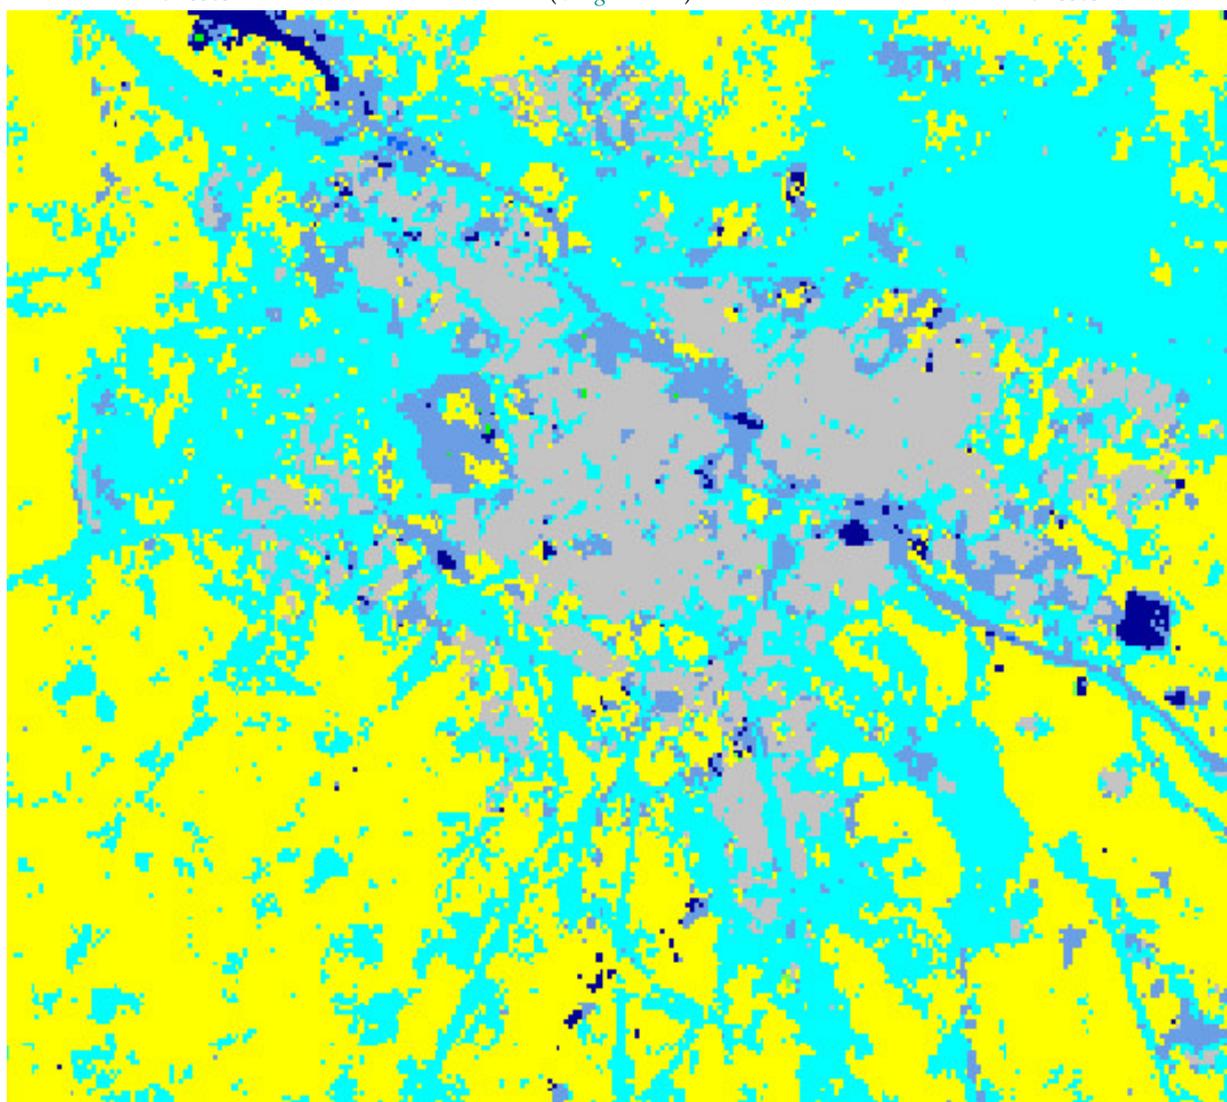
On compare ici les classifications des différents mois et de l’année complète 2018. Des différences de performance ont été constatées entre les classifications mensuelles et annuelle et étaient statistiquement significatives.



(A) Classification avec 5 classes

(B) Ortho-image (Google Earth)

(C) Classification avec 9 classes



(D) Zoom sur l'extrait de la classification avec 9 classes

FIG. 4.14 – Extraits de l'ortho-image et des classifications de séries temporelles d'images optiques Sentinel-2_L2A avec les légendes à 5 : ■ : VGT; ■ : AGR; ■ : EAU; ■ : RTE; ■ : BTM et 9 : ■ : FRT; ■ : PRA; ■ : ARB; ■ : AGR; ■ : SFE; ■ : ZHU; ■ : RIV; ■ : RTE; ■ : BTM classes, d'une zone urbaine sur la zone d'intérêt T33PUL.

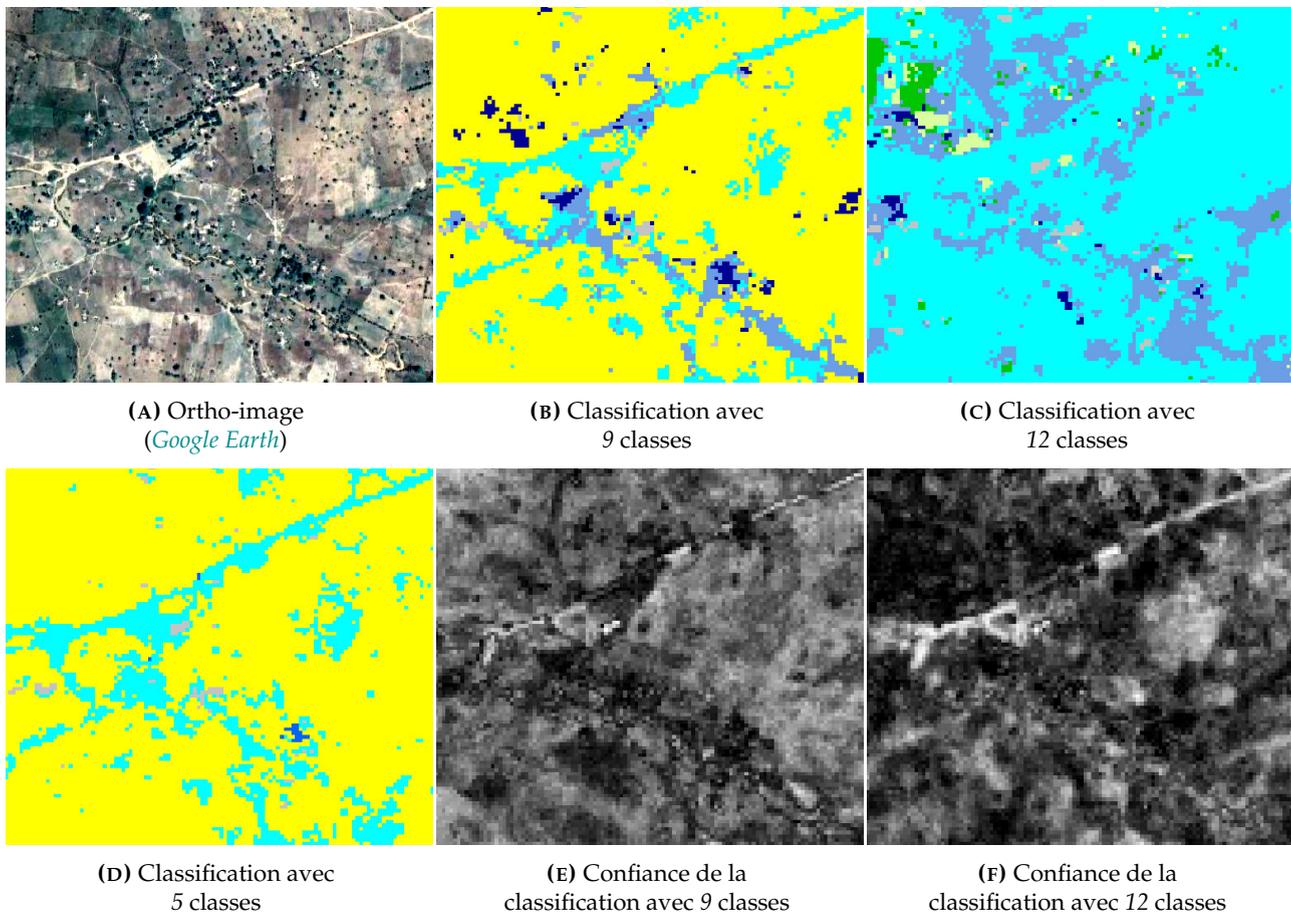


FIG. 4.15 – Extraits de l’ortho-image et des classifications et des confiances de classifications de séries temporelles d’images optiques Sentinel-2_L2A avec les légendes à 5 et 9 et 12 classes, de petites classes locales sur la zone d’intérêt *T33PUL*.

Le Tableau 4.6 présente les différentes valeurs de K et FS avec 9 classes, de la zone d’intérêt *T33PUL*. Les cellules en vert et orange clair correspondent respectivement aux valeurs maximales (paires de classifications mensuelles identiques) et assez faibles (paires de classifications mensuelles assez différentes). Dans ce tableau, on peut globalement observer de très faibles scores de similarité K et FS de la plupart des mois et de l’année complète 2018 avec des classifications très différentes entre elles. Les résultats sont rarement similaires. Il est en effet frappant de constater que même entre eux les résultats obtenus sont différents : cela implique **un taux d’accord très bas. Le taux d’accord est relié aux valeurs de K et de FS qui sont plus élevées dans chacune des classifications des mois d’avril, octobre et décembre et de l’année complète 2018 par rapport aux autres classifications mensuelles et annuelle et la VT qui possèdent ainsi les meilleurs taux d’accord.** Au contraire, les classifications des mois de juillet, août et septembre possèdent les plus faibles taux d’accord par rapport aux autres classifications.

4.5.1.5 Comparaison par région des distributions de classes des classifications sur *T33PUL*

Afin de comprendre les problèmes d’incertitudes spatiales et du bruit au niveau des pixels et choisir une combinaison de classifications similaires au vu de la difficulté à évaluer quantitativement et qualitativement les différentes classifications, une approche de comparaison par visualisation matricielle exploitant les matrices de confusion et un encodage couleur fondé sur la moyenne des

TAB. 4.6 – Coefficients Kappa (K) et F-Scores moyens (FS) obtenus au terme de la comparaison pixel à pixel des classifications mensuelles et annuelle de séries temporelles d'images optiques Sentinel-2_L2A et de la VT avec la légende à 9 classes, de la zone d'intérêt T33PUL.

	jan.		fév.		mar.		avr.		mai		juin		juil.		août.		sep.		oct.		nov.		déc.		2018		VT			
$k = 9$	K	FS	K	FS	K	FS	K	FS	K	FS	K	FS	K	FS	K	FS	K	FS	K	FS	K	FS	K	FS	K	FS	K	FS		
L2A																														
janvier	1,0	100,0	0,3	25,6	0,3	39,4	0,2	24,6	0,2	36,4	0,2	23,0	0,2	21,7	0,1	17,4	0,2	35,4	0,2	25,1	0,3	42,7	0,2	25,4	0,2	25,4	0,3	40,6	0,2	31,0
février	0,3	25,6	1,0	100,0	0,2	25,9	0,4	49,0	0,2	22,0	0,4	46,0	0,3	41,8	0,2	34,0	0,2	20,5	0,4	50,7	0,4	24,4	0,2	24,4	0,4	50,3	0,3	25,6	0,4	27,1
mars	0,3	39,4	0,2	25,9	1,0	100,0	0,3	27,3	0,2	34,2	0,2	26,2	0,2	20,6	0,1	16,7	0,2	30,5	0,2	26,2	0,3	39,5	0,2	39,5	0,2	25,7	0,4	53,2	0,2	32,3
avril	0,2	24,6	0,4	49,0	0,3	27,3	1,0	100,0	0,2	25,6	0,4	46,3	0,3	43,9	0,1	33,2	0,1	20,7	0,4	53,7	0,4	27,9	0,3	27,9	0,4	48,4	0,2	25,5	0,4	29,1
mai	0,2	36,4	0,2	22,0	0,2	34,2	0,2	25,6	1,0	100,0	0,2	22,7	0,2	22,8	0,1	17,4	0,2	32,0	0,2	25,8	0,3	39,9	0,2	39,9	0,2	23,0	0,3	36,6	0,2	29,7
juin	0,2	23,0	0,4	46,0	0,2	26,2	0,4	46,3	0,2	22,7	1,0	100,0	0,3	40,4	0,1	31,5	0,1	21,1	0,4	48,2	0,2	23,9	0,4	23,9	0,4	48,8	0,3	28,2	0,3	26,3
juillet	0,2	21,7	0,3	41,8	0,2	20,6	0,3	43,9	0,2	22,8	0,3	40,4	1,0	100,0	0,2	36,3	0,1	20,4	0,3	48,0	0,2	23,4	0,2	23,4	0,3	41,9	0,2	20,3	0,2	23,0
août	0,1	17,4	0,2	34,0	0,1	16,7	0,1	33,2	0,1	17,4	0,1	31,5	0,2	36,3	1,0	100,0	0,1	16,7	0,2	36,4	0,1	19,0	0,1	19,0	0,1	32,0	0,1	16,4	0,1	16,4
septembre	0,2	35,4	0,2	20,5	0,2	30,5	0,1	20,7	0,2	32,0	0,1	21,1	0,1	20,4	0,1	16,7	1,0	100,0	0,2	23,8	0,2	37,8	0,2	37,8	0,1	21,8	0,2	36,1	0,2	28,2
octobre	0,2	25,1	0,4	50,7	0,2	26,2	0,4	53,7	0,2	25,8	0,4	48,2	0,3	48,0	0,2	36,4	0,2	23,8	1,0	100,0	0,3	30,7	0,4	30,7	0,4	53,8	0,3	27,1	0,4	29,2
novembre	0,3	42,7	0,2	24,4	0,3	39,5	0,3	27,9	0,3	40,0	0,2	23,9	0,2	23,4	0,1	19,0	0,2	37,8	0,3	30,7	1,0	100,0	0,3	100,0	0,3	27,0	0,4	44,4	0,2	34,6
décembre	0,2	25,4	0,4	50,3	0,2	25,7	0,4	48,4	0,2	23,0	0,4	48,8	0,3	41,9	0,1	32,0	0,1	21,8	0,4	53,8	0,3	27,0	0,3	27,0	1,0	100,0	0,2	26,9	0,3	26,7
2018	0,3	40,6	0,3	25,6	0,4	53,2	0,2	25,5	0,3	36,6	0,3	28,2	0,2	20,3	0,1	16,4	0,2	36,1	0,3	27,0	0,4	44,4	0,2	44,4	0,2	26,9	1,0	100,0	0,3	38,6
VT	0,2	31,0	0,4	27,1	0,2	32,3	0,4	29,1	0,2	29,7	0,3	26,3	0,2	23,0	0,1	16,4	0,2	28,2	0,4	29,2	0,2	34,6	0,2	34,6	0,3	26,7	0,3	38,6	1,0	100,0

k : nombre de classes. VT : vérité terrain.

scores (distances euclidiennes entre les distributions de classes) calculés au sein de régions extraites de ces classifications, est proposée. En effet, en effectuant la moyenne des distances euclidiennes entre les distributions de classes calculées au sein de grandes cellules de tailles 200 pixels extraites de deux classifications données, une image des images des scores de comparaison par cellule correspondant à la moyenne de ces scores est produite.

Le Tableau 4.7 présente les moyennes des scores calculés au sein de cellules de taille 200 pixels extraites des classifications supervisées de séries temporelles d'images optiques Sentinel-2_L2A des douze mois et de l'année complète 2018 et de la VT utilisant la légende à 9 classes, de la zone d'intérêt T33PUL. Les résultats obtenus ici sont indicatifs en fonction du niveau de qualité des données utilisées. L'apport de l'approche de comparaison par visualisation matricielle est manifeste puisqu'elle traduit la tendance d'une classification par rapport aux autres.

Dans ce tableau, on peut globalement constater de fortes valeurs des scores de comparaison par région des classifications mensuelles et annuelle et la VT. Ce qui signifie que les différents résultats ne se ressemblent pas venant ainsi confirmer le résultat des comparaisons par pixel. **La classification du mois d'août est très différente des autres classifications avec des scores les plus élevés de 0,56 à 0,85, ce qui était tout à fait prévisible en raison de la mauvaise qualité de la série d'images Sentinel-2 pendant le mois d'août.** Par contre, les deux groupes de classifications mensuelles (février, juin, juillet et octobre) et (février, avril, juillet et décembre) se rapprochent des deux classifications des mois de septembre et novembre avec de faibles scores de 0,52 et 0,46 respectivement. De même, le groupe des classifications mensuelles (avril, juin et octobre) est davantage proche de la classification du mois de février avec un score plus faible de 0,27.

4.5.1.6 Influence de la nomenclature et de la dimension temporelle des données sur T33PUL

La nomenclature (légende) des données de référence et la dimension temporelle des données satellitaires (mensuelles ou annuelle) peuvent modifier les performances de classification. Ainsi, l'impact des périodes sur les résultats de classification précédemment étudiés pour les trois légendes (Section 4.5.1.1) est analysé dans cette section.

4.5.1.6.1 Influence de la nomenclature sur les classifications supervisées de la zone d'intérêt T33PUL La Section 4.5.1.1 montre qu'on obtient les résultats les plus forts des classifications de l'année complète 2018 pour les légendes à 5 et 9 classes si l'on considère les FS. Cependant, l'analyse des K révèle que les meilleurs résultats sont généralement obtenus pour les trois légendes. Bien que les résultats soient moins bons pour la légende à 12 classes, l'amélioration obtenue en fusionnant les classes d'OCS n'est pas si importante.

4.5.1.6.2 Influence de la dimension temporelle des données satellitaires sur les classifications supervisées de la zone d'intérêt T33PUL La Section 4.5.1.1 montre également qu'on obtient les résultats les plus forts pour les légendes à 5 et 9 classes, de la classification de la série annuelle complète (2018) si l'on considère les FS. Par contre, l'analyse des K révèle que les meilleurs résultats sont généralement obtenus pour les trois légendes, des classifications des mois de mars et décembre. Bien que les résultats des classifications du mois d'août soient moins bons pour les trois légendes, la classification de la série annuelle complète n'est pas si importante étant donné que les meilleurs résultats sont par ailleurs obtenus pour la légende à 9 classes, de la classification du mois de janvier.

<i>L2A</i>	jan.	fév.	mar.	avr.	mai	juin	juil.	août.	sep.	oct.	nov.	déc.	2018	<i>VT</i>
janvier	0.00	0.42	0.37	0.49	0.38	0.47	0.48	0.68	0.33	0.46	0.30	0.43	0.41	0.59
février	0.42	0.00	0.48	0.27	0.52	0.27	0.35	0.57	0.52	0.27	0.46	0.26	0.45	0.38
mars	0.37	0.48	0.00	0.48	0.42	0.46	0.51	0.70	0.45	0.46	0.32	0.47	0.27	0.57
avril	0.49	0.27	0.48	0.00	0.54	0.30	0.37	0.66	0.59	0.26	0.46	0.30	0.48	0.31
mai	0.38	0.53	0.42	0.54	0.00	0.55	0.50	0.70	0.43	0.48	0.34	0.52	0.46	0.64
juin	0.47	0.27	0.46	0.30	0.55	0.00	0.40	0.64	0.52	0.30	0.48	0.27	0.43	0.39
juillet	0.48	0.35	0.51	0.37	0.50	0.40	0.00	0.56	0.52	0.32	0.46	0.37	0.52	0.48
août	0.68	0.57	0.70	0.66	0.70	0.64	0.56	0.00	0.69	0.61	0.62	0.65	0.72	0.85
septembre	0.33	0.52	0.45	0.59	0.43	0.52	0.52	0.69	0.00	0.52	0.36	0.50	0.47	0.69
octobre	0.46	0.27	0.46	0.26	0.48	0.30	0.32	0.61	0.52	0.00	0.40	0.27	0.44	0.34
novembre	0.30	0.46	0.32	0.46	0.34	0.48	0.46	0.62	0.36	0.40	0.00	0.46	0.37	0.60
décembre	0.43	0.26	0.47	0.30	0.53	0.27	0.37	0.65	0.51	0.27	0.46	0.00	0.45	0.39
2018	0.41	0.45	0.27	0.48	0.46	0.43	0.52	0.72	0.47	0.44	0.37	0.45	0.00	0.48
<i>VT</i>	0.59	0.38	0.57	0.31	0.64	0.39	0.48	0.84	0.69	0.34	0.60	0.39	0.48	0.00

TAB. 4.7 – Moyennes des distances entre les histogrammes calculés au sein de cellules de taille 200 pixels extraites des classifications mensuelles et annuelle de séries temporelles d’images optiques Sentinel-2_L2A et de la vérité terrain (*VT*) avec la légende à 9 classes, de la zone d’intérêt T33PUL.

4.5.2 Zone d'intérêt T32NPL (ZONE2, Ouest-Centre)

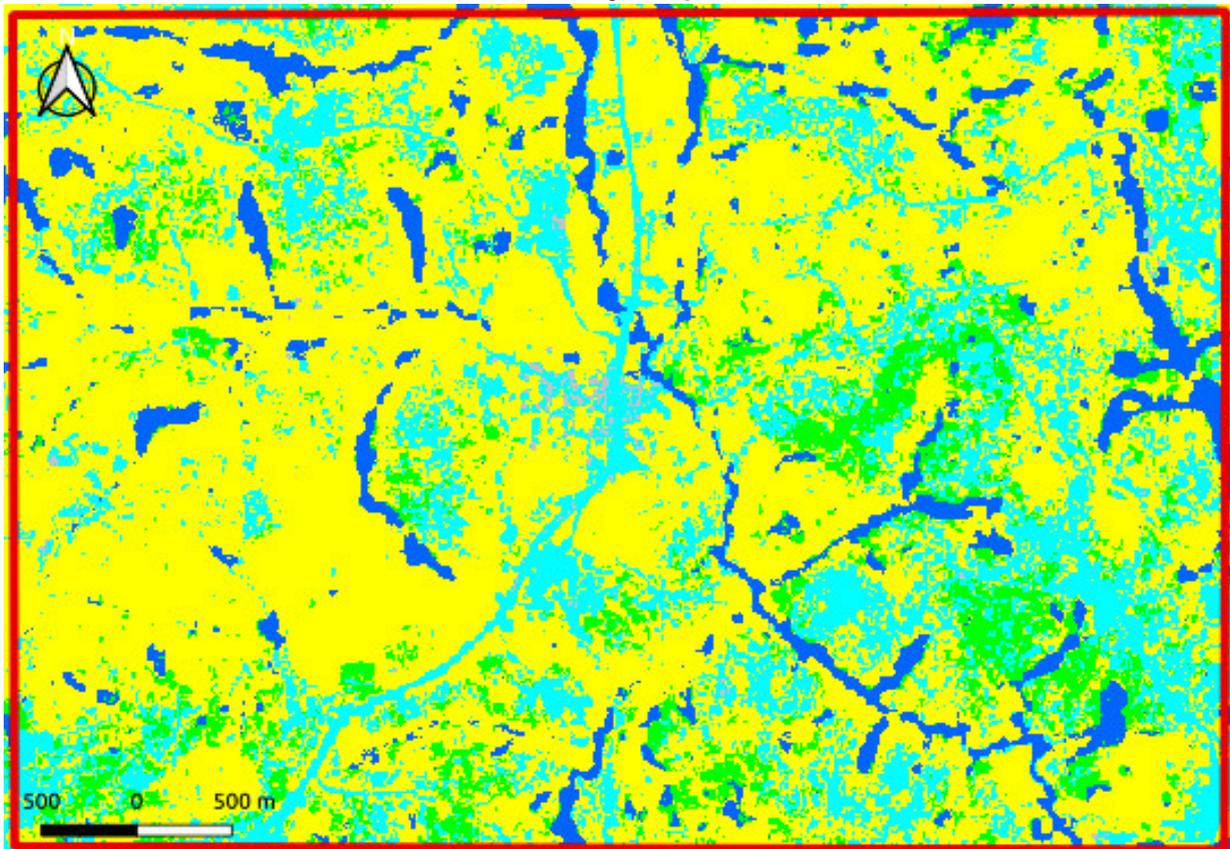
Les extraits d'ortho-image et des différentes classifications supervisées de séries temporelles d'images optiques Sentinel-2_L2A de l'année complète 2018 pour les légendes à 5, 9 et 12 classes, de la zone d'intérêt T32NPL sont présentées dans les Figures 4.16B, 4.17A et 4.17B respectivement.

4.5.2.1 Evaluation quantitative des classifications supervisées de la zone d'intérêt T32NPL

Les Figures 4.18 et 4.19 présentent respectivement FS et K pour chaque mois et pour l'année complète 2018 pour les trois légendes. Quelle que soit la légende utilisée dans les classifications, les valeurs de FS et de K avec les images optiques sont variables et faibles ($0,3 < FS < 0,43$ et $0,31 < K < 0,47$). **Les résultats les plus forts sont associés aux classifications de l'année complète pour les trois légendes si l'on considère les FS et aux classifications du mois de février pour la légende à 5 classes et de l'année complète pour les légendes à 9 et 12 classes si l'on considère les K.** Au contraire, les résultats les plus faibles sont associés aux classifications du mois d'août pour les trois légendes et du mois d'avril également pour la légende à 12 classes si l'on considère les FS et aux classifications du mois d'août pour les légendes à 5 et 12 classes et du mois d'avril pour la légende à 9 classes si l'on considère les K. Ces résultats sont en accord avec ceux obtenus dans la littérature, qui montrent les limitations des images optiques dans la cartographie des classes SFE et ZHU ainsi que des classes FFE et ZHH pour la légende à 12 classes qui se trouvent mieux discriminées pendant la saison pluvieuse comme c'est le cas dans les classifications des mois de juillet et d'août.

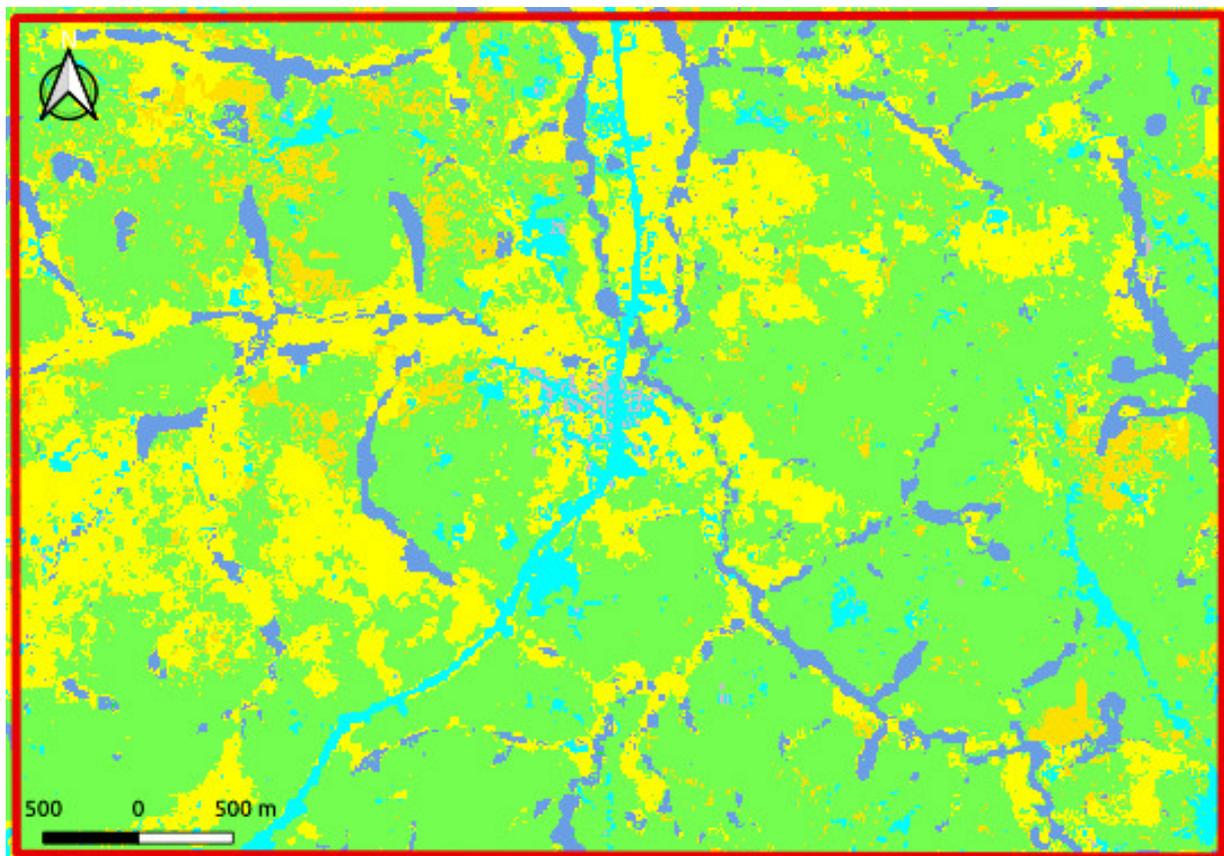
Les Figures 4.20, 4.21 et 4.22 présentent les métriques de qualité par classe. L'utilisation des légendes à 5 et 9 classes permet d'améliorer la classification annuelle des classes EAU (FS (EAU) $\simeq 0,08$); RTE (FS (RTE) $\simeq 0,19$) et BTM (FS (BTM) $\simeq 0,53$) pour la légende à 5 classes puis des classes ARB (FS (ARB) $\simeq 0,52$); AGR (FS (AGR) $\simeq 0,6$); SFE (FS (SFE) $\simeq 0,02$); ZHU (FS (ZHU) $\simeq 0,08$); RIV (FS (RIV) $\simeq 0,06$); RTE (FS (RTE) $\simeq 0,19$) et BTM (FS (BTM) $\simeq 0,52$) pour la légende à 9 classes. De plus, les classes VGT (FS (VGT) $\simeq 0,88$) et AGR (FS (AGR) $\simeq 0,53$) sont améliorées dans les classifications des mois d'octobre et décembre pour la légende à 5 classes tandis que la classe FRT (FS (FRT) $\simeq 0,87$) est améliorée dans la classification du mois de mars pour la légende à 9 classes. L'utilisation de la légende à 12 classes permet également d'améliorer la discrimination des classes VHB; FOU; FFE; TCU; ARB; ZHH; RIV; RTE et BTM et du mois de décembre des classes SFE (FS (SFE) $\simeq 0,05$) et ZHU (FS (ZHU) $\simeq 0,02$). **Les meilleurs résultats sont alors obtenus pour la légende à 5 classes, où le FS/classe atteint le FS (VGT) $\simeq 0,88$ de la classe VGT dans les classifications des mois d'octobre et décembre et les précisions PU et PP atteignent respectivement la PU (VGT) $\simeq 0,96$ de la classe VGT dans la classification du mois de février et la PP (BTM) $\simeq 0,83$ de la classe BTM dans la classification du mois d'août.**

La fusion des trois BDs en 12 classes, offre également de bonnes performances à l'ensemble des classifications mensuelles et annuelle. Par contre, ces classifications sont de moins bonne qualité pour la majorité des mois comparativement à celles correspondant à 5 et 9 classes. Ce résultat montre que la légende constituée par ajout de BDs est plus complexe donnant plus de chance de se tromper entre sous classes en plus du fait que la VT est très grossière. Tout ceci rend l'apprentissage du classifieur beaucoup plus complexe et dégrade ainsi les performances des classifications mensuelles **même si la classe PRA est la seule à être très peu détectée dans les classifications mensuelles au point de n'apparaître qu'en trace dans la classification annuelle, la classe VNC n'est par contre détectée dans aucune des classifications mensuelles et annuelle pour la légende à 9 classes.** Par conséquent, il est

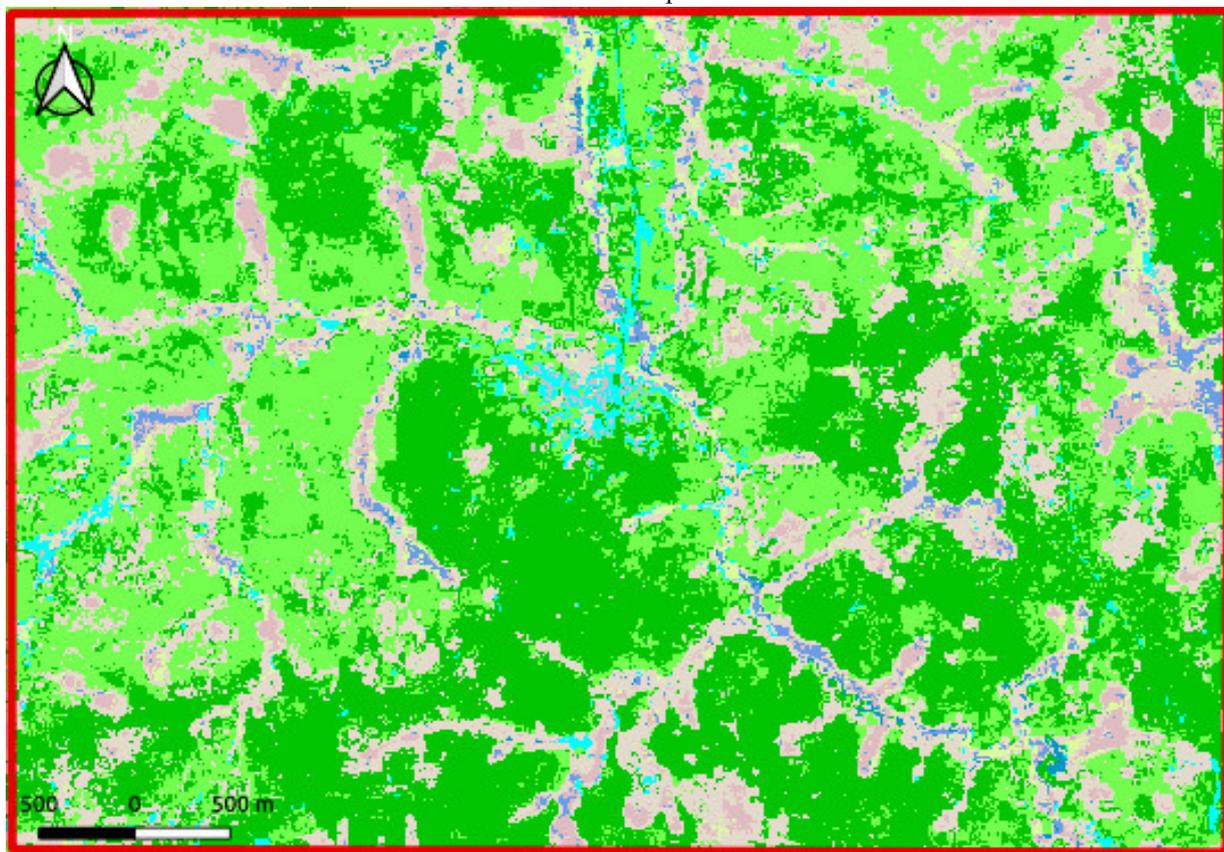
(A) Ortho-image (*Google Earth*)

(B) Classification de l'année complète 2018 avec 5 classes

FIG. 4.16 – Extraits de l'ortho-image et de la classification supervisée de séries temporelles d'images optiques Sentinel-2_L2A avec la légende à 5 classes : ■ : VGT ; ■ : AGR ; ■ : EAU ; ■ : RTE ; ■ : BTM, de la zone d'intérêt T32NPL.



(A) Classification de l'année complète 2018 avec 9 classes



(B) Classification de l'année complète 2018 avec 12 classes

FIG. 4.17 – Extraits des classifications supervisées d'images Sentinel-2_L2A avec les légendes à 9 : ■ : FRT; ■ : PRA; ■ : ARB; ■ : AGR; ■ : SFE; ■ : ZHU; ■ : RIV; ■ : RTE; ■ : BTM et 12 : ■ : VNC; ■ : VHB; ■ : FOU; ■ : FFE; ■ : TCU; ■ : ARB; ■ : ZHH; ■ : SFE; ■ : ZHU; ■ : RIV; ■ : RTE; ■ : BTM classes, de la zone d'intérêt T32NPL.

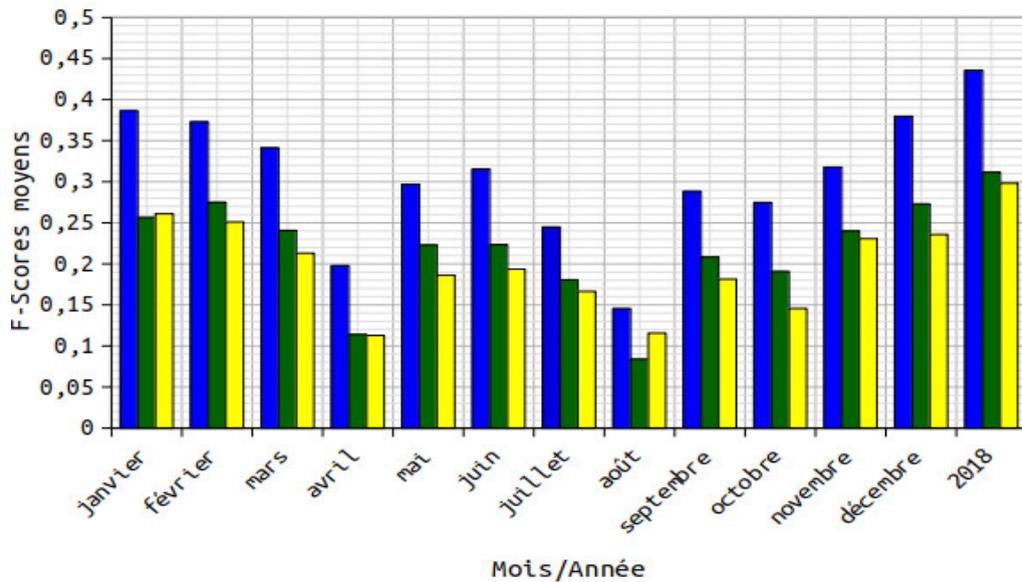


FIG. 4.18 – F-Scores moyens des classifications supervisées de séries d’images Sentinel-2_L2A avec les légendes à 5 et 9 et 12 classes, de la zone d’intérêt T32NPL.

plus judicieux de combiner l’ensemble des séries mensuelles en une série annuelle pour la classification d’un nombre élevé de classes d’OCS.

La fusion des classes FRT ; PRA et ARB dans la légende à 9 classes en la classe VGT de la légende à 5 classes offre de nouveau des résultats contrastés. En effet, l’utilisation de la classe VGT augmente grandement les performances de la classification annuelle (FS = 0,43 ; PU (VGT) \simeq 0,96) pour la légende à 5 classes, alors que le FS est de 0,31 lorsque les classes FRT ; PRA et ARB sont considérées indépendamment (PU (FRT) \simeq 0,94 ; PU (PRA) \simeq 0,02 et PU (ARB) \simeq 0,46) pour la légende à 9 classes. Les valeurs de FS et de PU restent cependant de moins bonne qualité pour la classification annuelle avec les images Sentinel-2 seules. **La fusion des classes FRT ; PRA et ARB n’est donc pas un choix suffisant et pertinent en raison des faibles valeurs de FS de la classification annuelle pour cette réagrégation en 5 classes.** Dans ce cas, la fusion des classes d’OCS induit davantage de bruit que d’étiquette utile dans la classification utilisant uniquement Sentinel-2.

Les faibles performances des classes RTE et BTM dans les mois d’avril, juillet et d’août (9 classes) sont dues aux manques de données de référence ainsi que la saison pluvieuse dans cette zone. De même, les faibles performances de FOU et FFE pour août et octobre (12 classes) sont à mettre en regard de l’activité photosynthétique de ces classes d’OCS. En effet, **les éléments agro-naturels issus de chacune des deux paires de classes, peuvent avoir des réflectances très proches avec les images optiques durant les mois d’août et octobre.** Ceci constitue une limite pour les classifications mais également pour l’obtention préalable du contour d’un parcellaire correspondant à une unité simple d’OCS. Différentes classes d’OCS contiguës peuvent être regroupées dans une seule classe et une classe hétérogène peut correspondre à plusieurs autres classes d’OCS. Ces limites liées à la réalisation de classifications pour des données qui ne sont vraiment pas de référence peuvent donc impacter les résultats globaux mais également les confusions.

Afin de permettre l’analyse détaillée **des erreurs de classification de la zone T32NPL par rapport à T33PUL**, les Tableaux 4.8, 4.9 et 4.10 montrent les matrices de confusion de 5, 9 et 12 classes sur

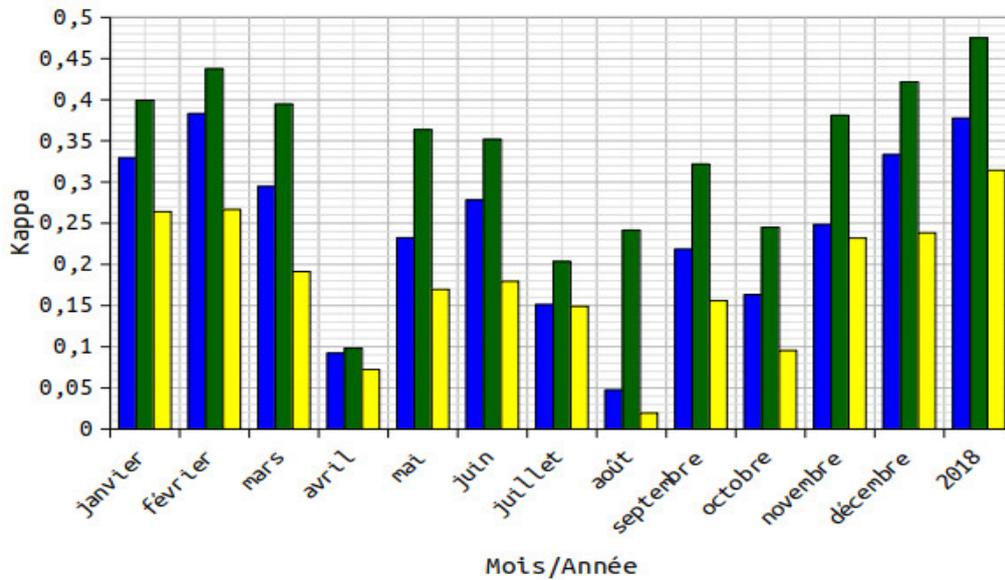


FIG. 4.19 – Coefficients Kappa des mêmes classifications que les FS dans la Figure 4.20.

T32NPL. Pour toutes les légendes, il existe des confusions récurrentes entre les classes en utilisant les données optiques seules.

Les pixels identifiés en classe VGT se trouvent moins classifiés en AGR et le taux de *FP*, avec la classe AGR, baisse ici grandement de 38,9% à 15,7% avec l'utilisation de Sentinel-2 seules pour la légende à 5 classes. La confusion s'atténue également fortement avec l'utilisation des classes FRT et PRA et les taux de *FP* baissent de 14,5% à 9,2% pour la classe FRT et de 13% à 2% pour la classe PRA. Par contre, la confusion s'accroît plutôt avec la classe ARB, et le taux de *FP* augmente de 17,3% à 20%. Concernant la confusion avec la classe EAU, elle s'atténue et le taux de *FP* baisse pour la légende à 5 classes et s'accroît et le taux de *FP* augmente pour la légende à 9 classes en affectant principalement l'optique. Cependant, cette confusion devient très faible avec l'ajout de nouvelles classes pour la légende à 12 classes. C'est ainsi que **la confusion entre les classes VNC et RIV s'atténue fortement avec un taux de *FP* qui baisse drastiquement de 38,3% à 0,1%. Cette diminution de *FP* se fait au détriment des *FN*, avec une forte augmentation de ceux-ci lors de l'utilisation d'images optiques seules.**

Par ailleurs, à 5 classes sur *T32NPL*, la classe RTE est classifiée en AGR avec un taux de *FP*=21,4%. À l'inverse, la classe AGR est classifiée en RTE avec un taux inférieur de *FN*=13,3%. Ce taux baisse et devient *FN*=12,5% de même que le taux de *FP* qui devient *FP*=19,3% et la confusion s'atténue donc pour la légende à 9 classes. De plus, pour cette légende, les classes SFE et RIV sont classifiées en RTE et ARB avec des taux de *FP*=25,4% et *FP*=11,6% respectivement. Inversement, les classes RTE et ARB sont classifiées en SFE et RIV avec des taux très inférieurs de *FN*=0% et *FN*=6,3%. Ces taux restent constants ou baissent encore et deviennent *FN*=0% et *FN*=1,2% de même que les taux de *FP* qui deviennent respectivement *FP*=19,2% et *FP*=0,7% et les confusions s'atténuent donc pour la légende à 12 classes. En outre, pour la légende à 9 classes, la classe RTE est classifiée en RIV avec un petit taux de *FP*=2%. À l'inverse, la classe RIV est classifiée en RTE avec un taux légèrement inférieur de *FN*=1,9%. Ce taux est multiplié par 2 et devient *FN*=3,8% de même que le taux de *FP* qui augmente grandement et devient *FP*=47,1% et la confusion s'accroît dans ce cas pour la légende à 12 classes. En général, **les taux de *FN* augmentent et la discrimination des classes d'OCS est ici meilleure**

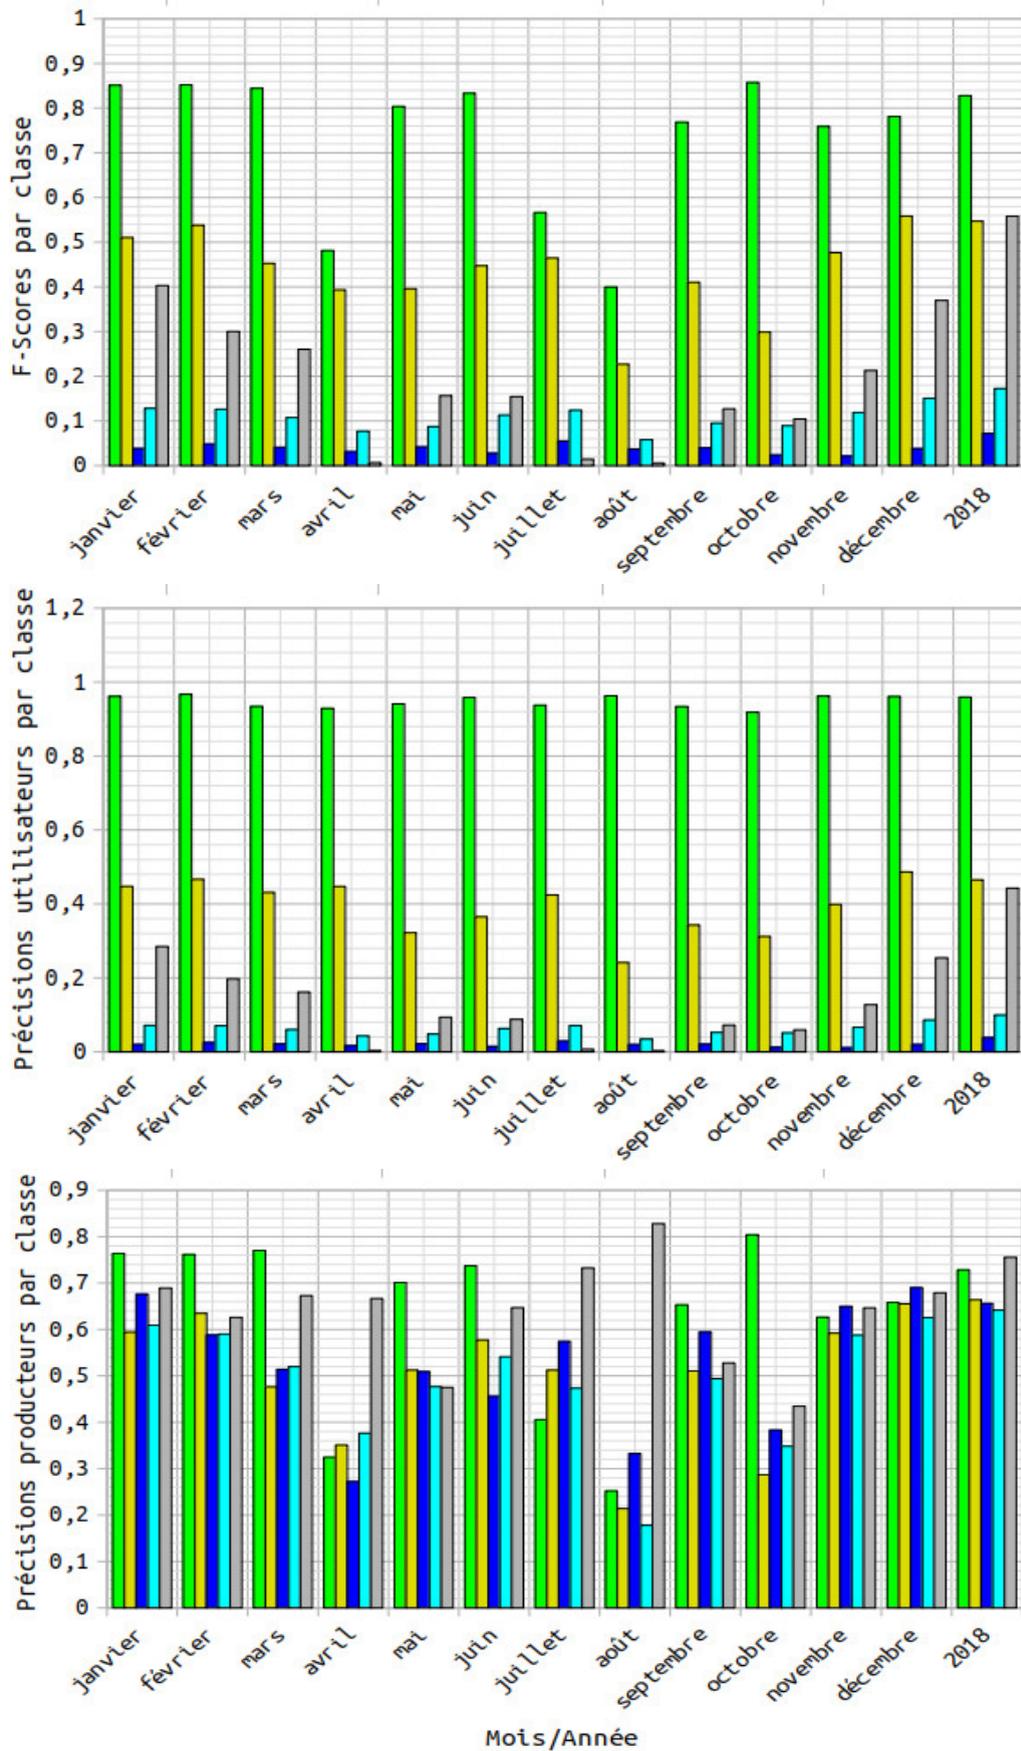


FIG. 4.20 – F-Scores et précision utilisateur et précision producteur par classe des classifications supervisées de séries temporelles d’images optiques Sentinel-2_L2A avec la légende à 5 classes : ■ : VGT; ■ : AGR; ■ : EAU; ■ : RTE; ■ : BTM, de la zone d’intérêt T32NPL.

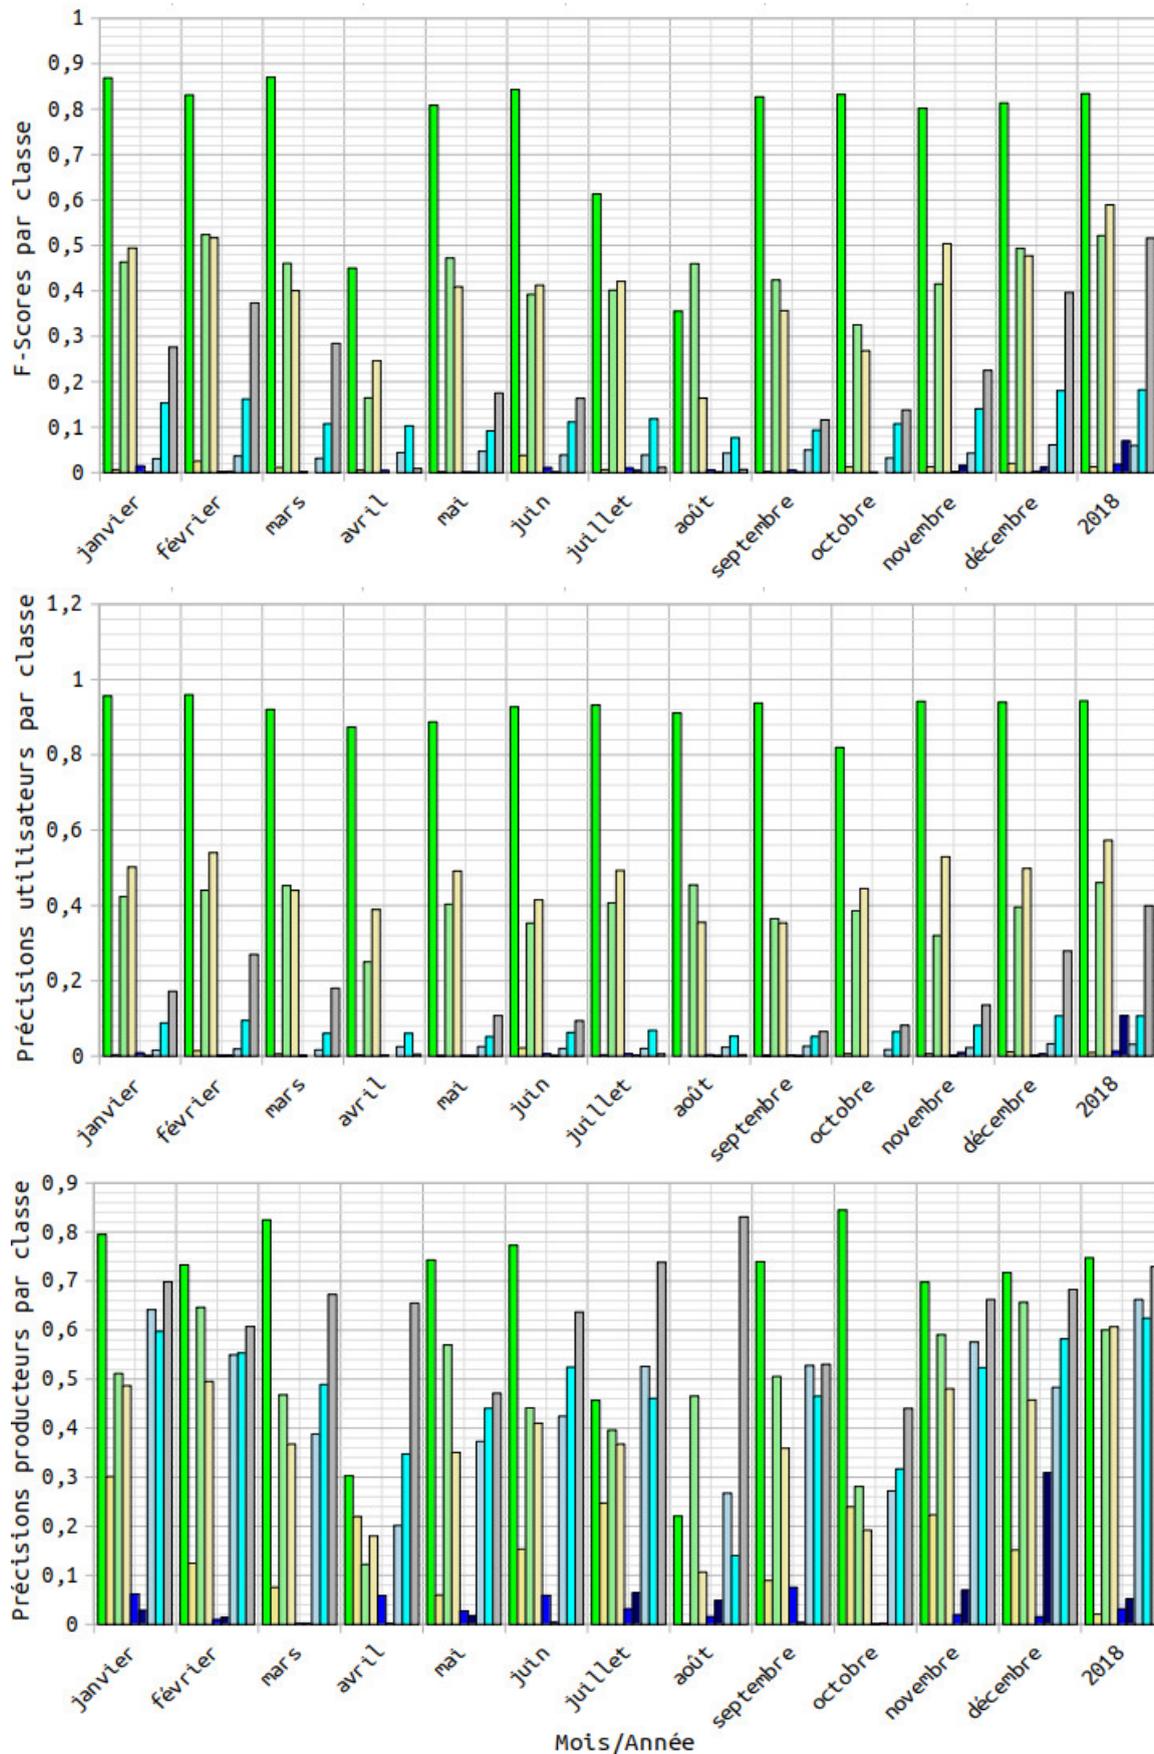


FIG. 4.21 – F-Scores et précision utilisateur et précision producteur par classe des classifications supervisées de séries temporelles d’images optiques Sentinel-2_L2A avec la légende à 9 classes : ■ : FRT; ■ : PRA; ■ : ARB; ■ : AGR; ■ : SFE; ■ : ZHU; ■ : RIV; ■ : RTE; ■ : BTM, de la zone d’intérêt T32NPL.

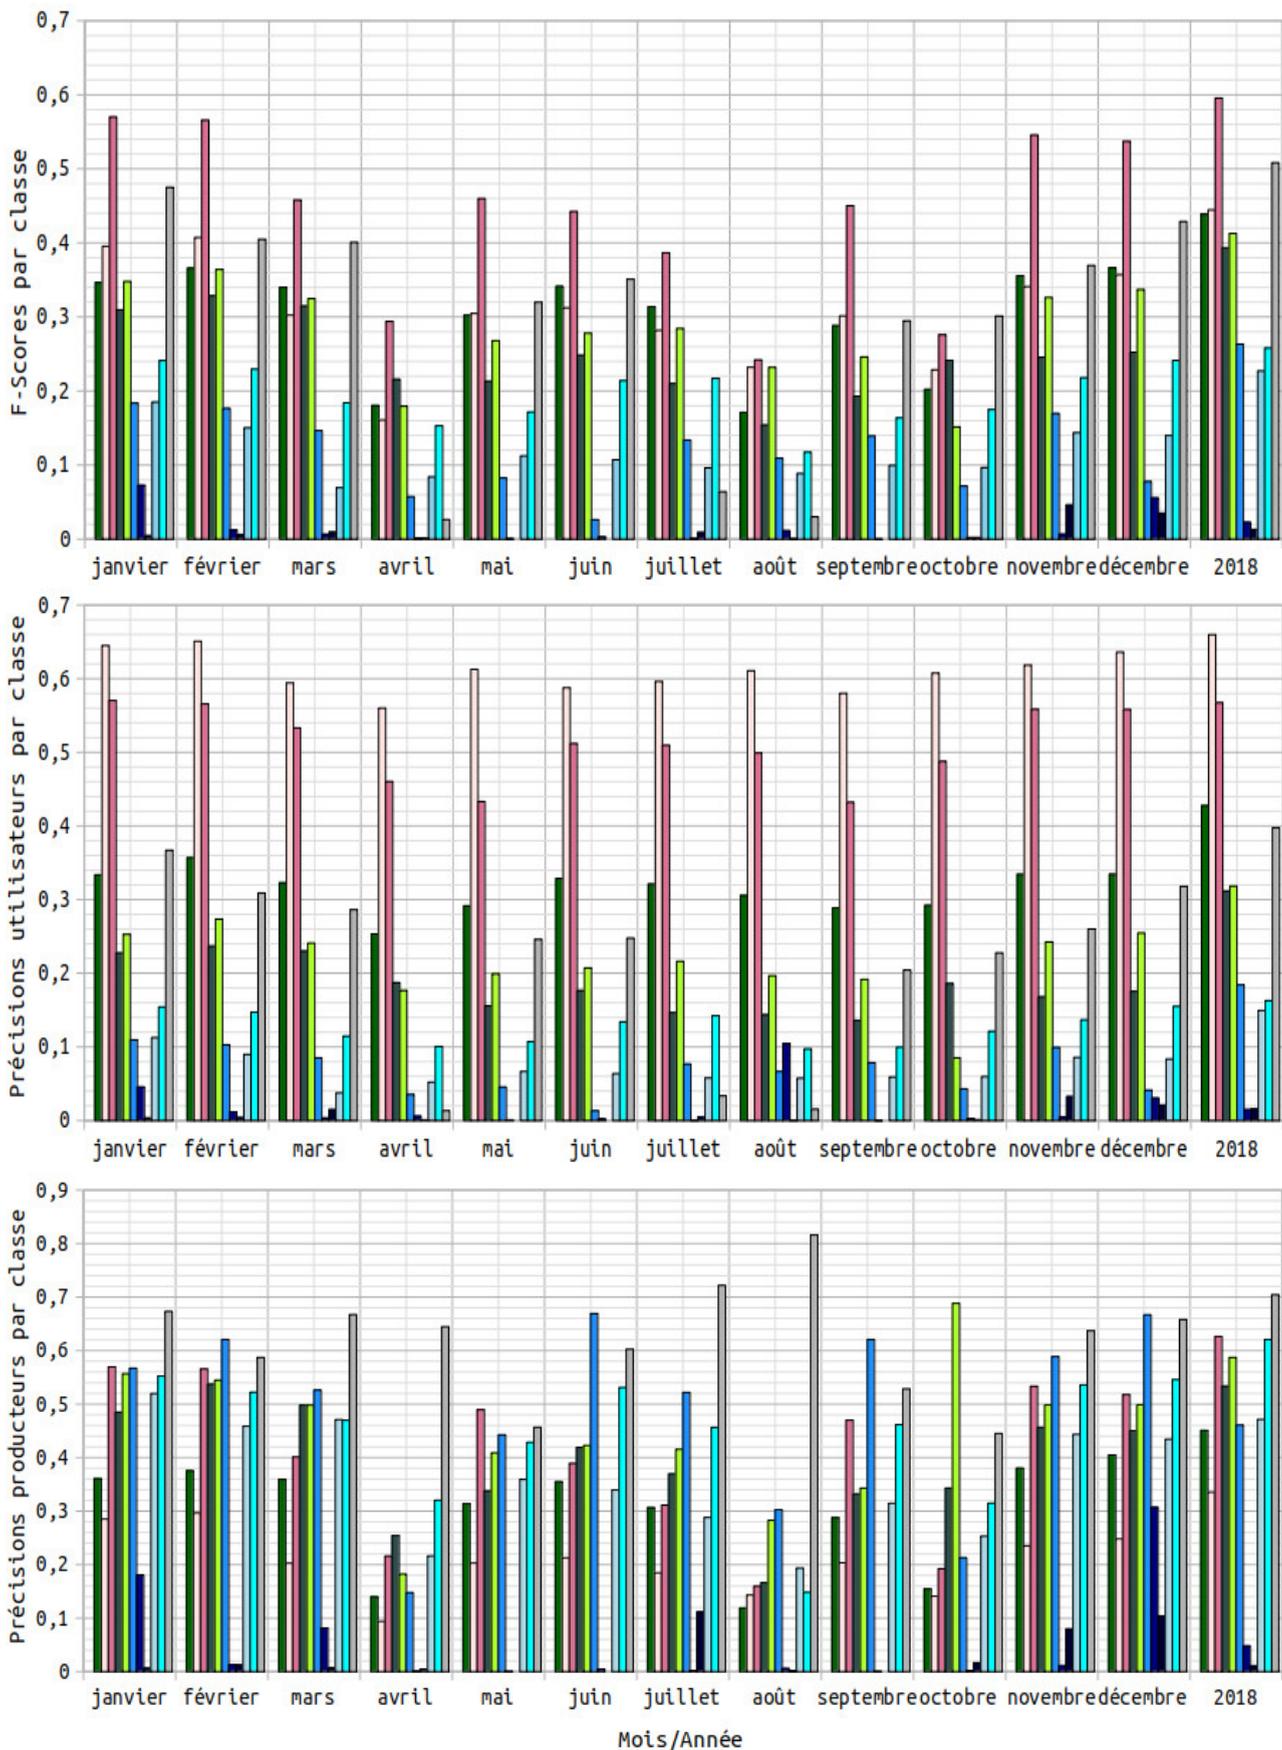


FIG. 4.22 – F-Scores et précision utilisateur et précision producteur par classe des classifications supervisées de séries temporelles d’images optiques Sentinel-2_L2A avec la légende à 12 classes : ■ : VNC; ■ : VHB; ■ : FOU; ■ : FFE; ■ : TCU; ■ : ARB; ■ : ZHH; ■ : SFE; ■ : ZHU; ■ : RIV; ■ : RTE; ■ : BTM, de la zone d’intérêt T32NPL.

à quelques exceptions près telles que les classes RTE et RIV dont la confusion reste notoire en utilisant seulement Sentinel-2_L2A pour 9 et 12 classes.

TAB. 4.8 – Matrice de confusion avec la légende à 5 classes.

L2A		Vérité Terrain					PU
% VU	CL	VGT	AGR	EAU	RTE	BTM	
73,1	VGT	72,8	13,9	20,2	6,2	0,1	95,9
11,4	AGR	15,7	66,4	11,0	21,4	3,2	46,5
0,1	EAU	8,3	5,6	65,6	2,6	0,4	3,8
0,1	RTE	3,0	13,3	3,0	64,1	20,8	10,0
0,1	BTM	0,2	0,8	0,2	5,7	75,6	44,3
	PP	72,8	66,4	65,6	64,1	75,6	

TAB. 4.9 – Matrice de confusion avec la légende à 9 classes.

L2A		Vérité Terrain								PU	
% VU	CL	FRT	PRA	ARB	AGR	SFE	ZHU	RIV	RTE		BTM
65,5	FRT	74,7	3,2	8,8	11,5	8,6	5,2	13,5	5,9	2,0	94,3
0,1	PRA	0,1	52,7	0,6	0,1	0,0	0,0	0,1	0,1	0,0	0,9
7,5	ARB	6,9	33,2	60,0	11,1	8,1	0,1	11,6	5,0	0,7	46,1
11,4	AGR	9,2	2,0	20,0	60,7	3,1	36,1	6,0	19,3	3,8	57,3
0,1	SFE	0,0	0,0	0,0	0,0	36,4	0,0	0,5	0,0	0,0	1,3
0,1	ZHU	0,0	0,0	0,0	0,0	0,0	49,6	0,0	0,0	0,0	10,7
0,1	RIV	8,1	0,3	6,3	3,1	17,9	8,3	66,2	2,0	0,4	3,1
0,1	RTE	0,9	7,7	4,0	12,5	25,4	0,7	1,9	62,4	20,1	10,7
0,1	BTM	0,1	0,9	0,3	0,9	0,6	0,0	0,2	5,4	72,9	39,9
	PP	74,7	52,7	60,0	60,7	36,4	49,6	66,2	62,4	72,9	

TAB. 4.10 – Matrice de confusion avec la légende à 12 classes.

L2A		Vérité Terrain											PU	
% VU	CL	VNC	VHB	FOU	FFE	TCU	ARB	ZHH	SFE	ZHU	RIV	RTE		BTM
0,1	VNC	80,2	0,2	0,2	0,2	0,2	0,2	0,2	0,2	0,2	0,2	0,0	0,2	0,2
3,1	VHB	0,1	45,1	10,7	1,2	3,9	22,2	2,2	0,1	0,0	0,6	2,0	0,2	42,7
1,1	FOU	0,1	15,8	33,5	18,9	11,0	8,6	4,0	3,3	0,4	6,9	6,8	0,9	66,0
1,0	FFE	0,1	7,1	23,3	62,6	6,3	2,2	6,8	4,8	30,2	22,9	11,6	2,9	56,7
1,6	TCU	0,1	2,1	6,0	3,4	53,3	0,9	0,1	0,1	0,0	6,3	7,2	3,5	31,1
0,2	ARB	0,1	18,9	10,9	1,1	5,3	58,7	0,5	0,0	0,0	0,7	1,6	0,3	31,8
0,1	ZHH	0,2	0,6	0,3	0,3	0,1	0,1	46,1	0,5	1,1	11,1	0,0	0,0	18,4
0,1	SFE	0,3	0,1	0,0	0,0	0,0	0,0	6,5	51,3	0,0	0,2	0,0	0,0	1,5
0,1	ZHU	0,2	0,0	0,0	0,0	0,0	0,0	0,3	0,2	38,1	0,0	0,0	0,0	1,6
0,1	RIV	0,1	0,9	2,6	2,6	5,7	1,2	0,4	30,7	19,8	28,3	47,1	4,0	15,0
0,1	RTE	0,1	8,7	11,4	6,3	14,9	6,3	2,7	19,2	2,0	3,8	62,1	21,5	16,3
0,1	BTM	0,2	0,8	1,2	0,4	3,9	0,7	0,0	0,6	0,0	0,2	4,7	70,4	39,7
	PP	80,2	45,1	33,5	62,6	53,3	58,7	46,1	51,3	38,1	28,3	62,1	70,4	

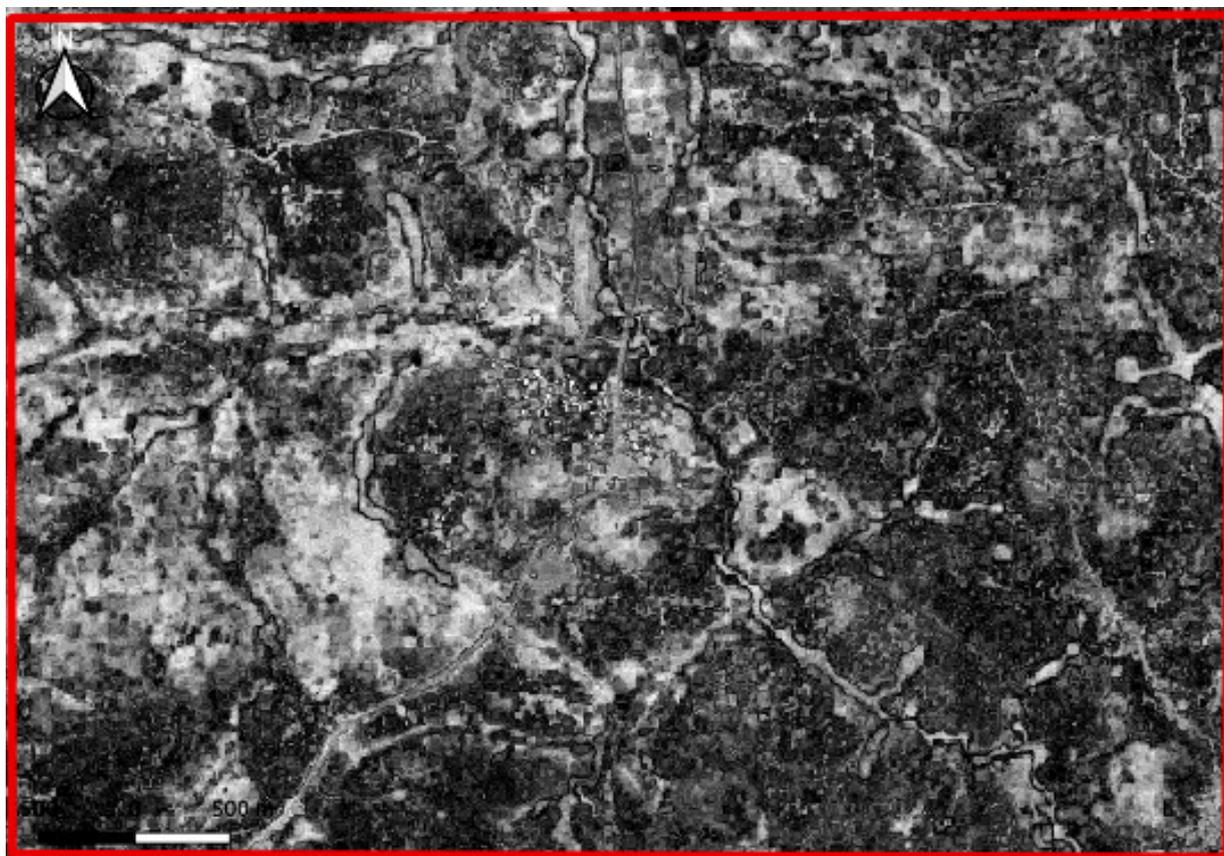
% VU : pourcentage de données vecteurs utilisées.

CL : classification.

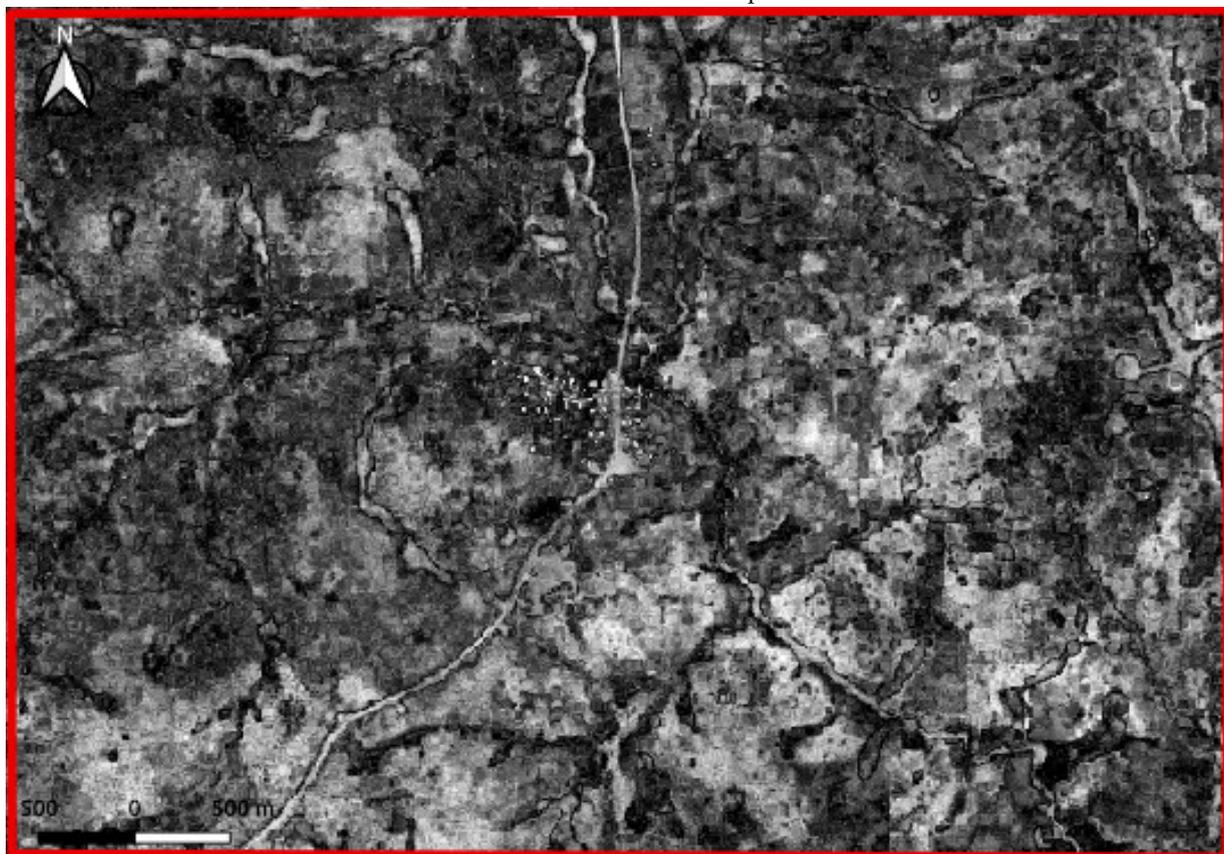
4.5.2.2 Utilisation des confiances des classifications de la zone d'intérêt T32NPL

Les Figures 4.23A, 4.23B et 4.24 montrent les extraits de cartes de confiance obtenues correspondantes aux classifications supervisées de la zone d'intérêt T32NPL dans les Figures 4.16B, 4.17A et 4.17B pour les légendes à 5, 9 et 12 classes respectivement.

Étant donné que la confiance dépend non seulement du nombre de dates pour lesquelles chaque pixel est valide, mais également de la légende, on peut voir identiquement à la zone d'intérêt T33PUL que les valeurs de confiance diminuent globalement lorsque le nombre de classes augmente. Par contre, la confiance se trouve renforcée localement lorsque le nombre de classes augmente comme



(A) Confiance de la classification de l'année complète 2018 avec 5 classes



(B) Confiance de la classification de l'année complète 2018 avec 9 classes

FIG. 4.23 – Extraits des confiances de classifications supervisées de séries temporelles d'images optiques Sentinel-2_L2A : ■ : faibles → ■ : fortes valeurs, de la zone d'intérêt T32NPL.

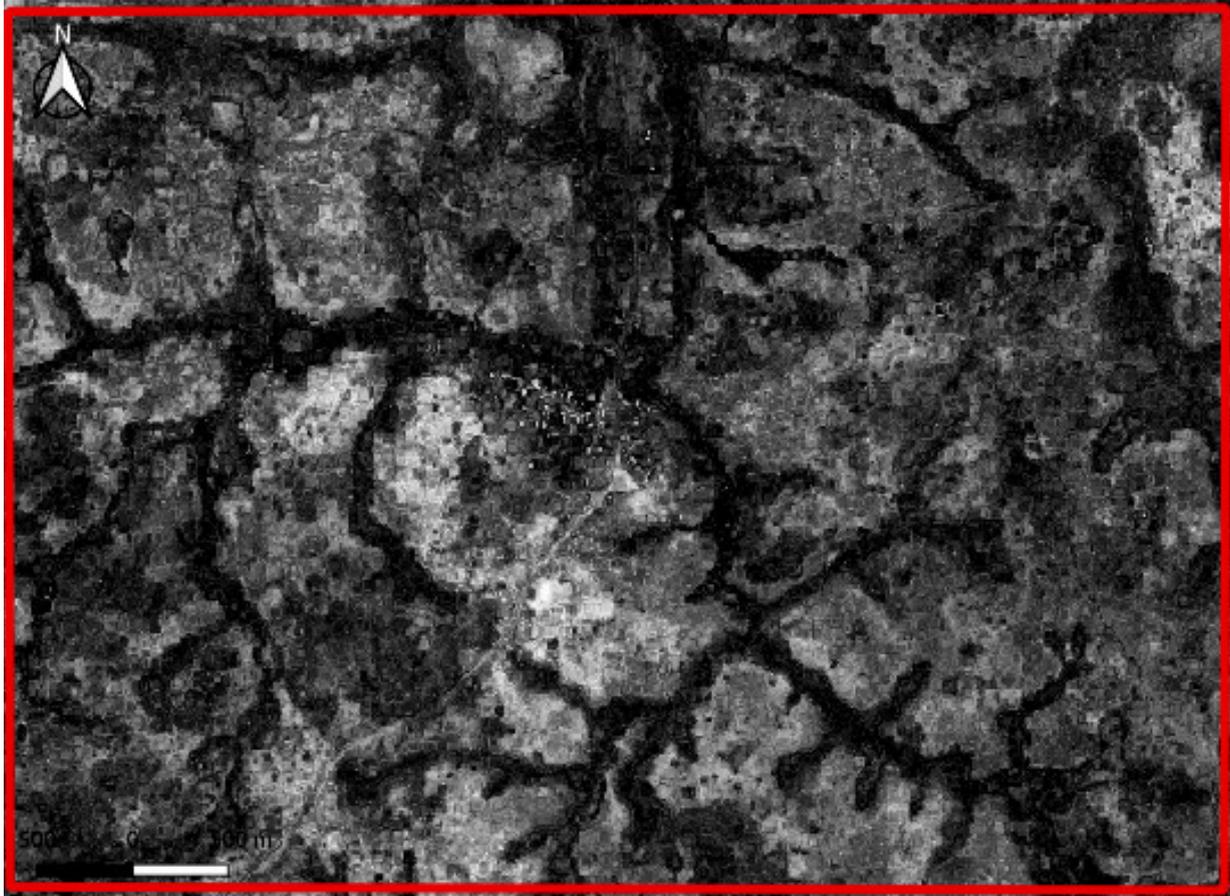


FIG. 4.24 – Extrait de la confiance de la classification supervisée de séries d’images Sentinel-2_L2A avec la légende à 12 classes, de la zone d’intérêt T32NPL.

c’est le cas pour la légende à 12 classes. Toutefois, l’effet de la présence d’une importante quantité de nuages et leurs ombres sur la zone d’intérêt T32NPL rend les classes d’OCS des légendes à 9 et 12 classes difficilement reconnaissables dans la partie ouest des Figures 4.25B et 4.26.

4.5.2.3 Evaluation qualitative des classifications supervisées de la zone d’intérêt T32NPL

De façon identique à la zone d’intérêt T33PUL, une évaluation visuelle permet d’analyser différents problèmes identifiés sur la zone d’intérêt T32NPL.

4.5.2.3.1 Paysages difficiles dans les classifications supervisées de la zone d’intérêt T32NPL Les métriques quantitatives n’étant pas en mesure de révéler tous les types d’erreurs présentes sur les classifications de grandes étendues, l’étude qualitative comparative visuelle des classifications pour les trois légendes est également détaillée dans cette section, sur deux types de zones : **une zone rurale (Figure 4.25) et une zone urbaine (Figure 4.26).**

La zone rurale est majoritairement composée de champs, de deux rivières qui s’intersectent au nord dont l’une située dans la partie nord, traverse l’image sur un axe ouest-est et l’autre traverse l’ortho-image sur un axe nord-sud, d’une zone humide éparse autour de la rivière au nord et de deux pistes traversant également l’ortho-image sur un axe ouest-est (Figure 4.25A). Les différentes classifications et confiances de classification pour les trois légendes sont représentées sur les Figures 4.25B-F. Les classes PRA et ARB ressortent bien pour la légende à 9 classes sur la Figure 4.25C : la

classification permet dans ce cas d'isoler les classes de végétation de manière individuelle, mais elle ne permet pas d'identifier clairement la classe VGT qui se confond trop souvent avec la classe RTE pour la légende à 5 classes (Figure 4.25B). On peut également noter un peu de confusions entre les paires de classes (PRA et SFE) et (PRA et AGR) pour la légende à 9 classes (Figure 4.25C). Par contre, la classification de la classe ARB est meilleure. En effet, le classifieur est plus confiant au niveau des arbustes, il y a toutefois un peu de confusion avec la classe FRT. De manière similaire, les classes FOU et FFE de la légende à 12 classes (Figure 4.25D) sont assez bien représentées. Cependant, mise à part ces six classes, les autres posent problème. Par exemple, la classe RIV est presque totalement confondue avec la classe AGR pour la légende à 9 classes (Figure 4.25C). La classe VNC contient des zones d'ombres et la classe VHB fait ressortir la végétation herbacée pour la légende à 12 classes.

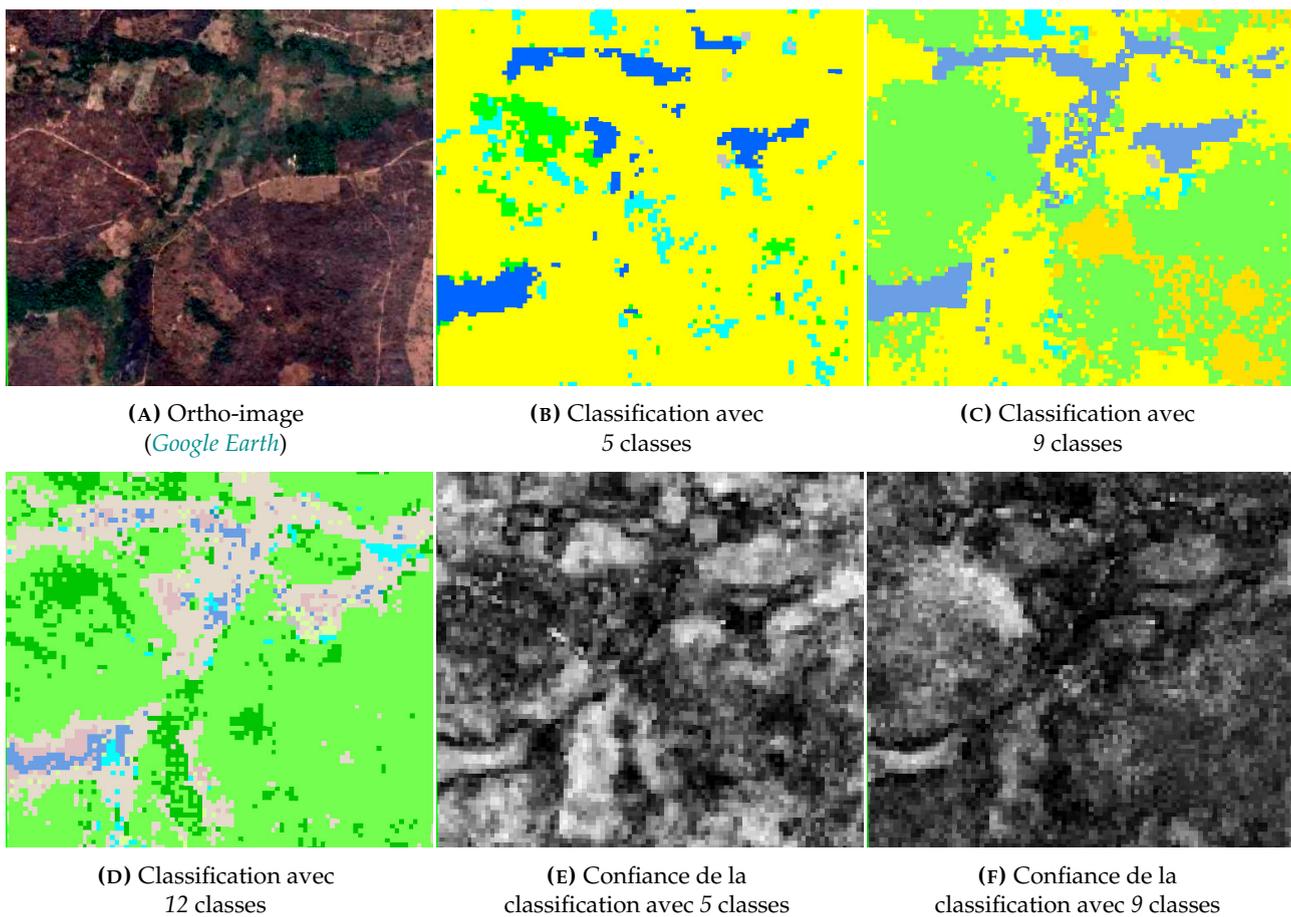


FIG. 4.25 – Extraits de l'ortho-image et des classifications et des confiances de classifications de séries temporelles d'images optiques Sentinel-2_L2A avec les légendes à 5 et 9 et 12 classes, d'une zone rurale sur la zone d'intérêt T32NPL.

La zone urbaine se situe dans le centre-ville de la zone d'intérêt T32NPL, elle est composée d'habitations concentrées près de la route principale qui traverse l'ortho-image sur un axe nord-sud, de routes secondaires et de rivières (Figure 4.26B). Pour la légende à 5 classes, la classification des classes RTE et BTM (Figure 4.26A) donne de très bons résultats permettant de les distinguer avec seulement quelques petites confusions apparaissant entre ces classes du fait des zones mixtes que doivent probablement contenir les données de référence constituées de polygones grossiers dégradant la qualité de la classification. Cependant les classes ZHU et RIV (Figure 4.26C(D)) de la légende à 9 classes (qui sont contenues dans la classe EAU de la légende à 5 classes) sont plutôt détectées en trace, sauf certaines

petites rivières (RIV) sont assez bien représentées pour la légende à 9 classes. **Cette faible détection, que l'on avait déjà observée sur la zone rurale, pourrait être facilement améliorée par exemple en utilisant les synthèses mensuelles de séries temporelles d'images optiques Sentinel-2_L3A.**

4.5.2.3 Petites classes locales dans les classifications supervisées de la zone d'intérêt T32NPL

Les classes minoritaires sont difficiles à cartographier en raison de la quantité insuffisante de données de référence représentatives pour ces classes. Des exemples typiques sont les classes VNC ; VHB ; ZHU et RIV. Ces classes sont concentrées dans des régions spécifiques de la zone T32NPL. La Figure 4.27C illustre comment **la légende à 5 classes réduit la confusion entre les classes RTE et AGR.**

4.5.2.4 Comparaison pixel à pixel des classifications sur T32NPL

L'objectif de cette section est d'effectuer la comparaison pixel à pixel entre les classifications des différents mois et de l'année complète 2018, de la zone d'intérêt T32NPL.

Le Tableau 4.11 présente les différentes valeurs du coefficient Kappa (K) et du F-Score moyen (FS) obtenues au terme de la comparaison pixel à pixel des classifications supervisées de séries temporelles d'images optiques Sentinel-2_L2A des douze mois et de l'année complète 2018 et de la VT utilisant la légende à 9 classes de la zone d'intérêt T32NPL.

Dans ce tableau, on peut globalement observer de très faibles scores de similarité K et FS issus de la comparaison entre les classifications de la plupart des mois et de l'année complète 2018 et la VT, traduisant ici le fait que ces classifications sont très différentes entre elles. Les résultats sont rarement similaires entre deux classifications. Ce qui implique **un taux d'accord très bas entre les différentes classifications. Ici, les valeurs de K et de FS sont plus élevées dans les classifications des mois de janvier, février et novembre et de l'année complète 2018 par rapport aux autres classifications mensuelles et annuelle et la VT qui possèdent ainsi les meilleurs taux d'accord.** Au contraire, le désaccord entre les classifications des mois d'avril, août et octobre et le reste des classifications est remarquable montrant ainsi les plus faibles valeurs de K et de FS.

4.5.2.5 Comparaison par région des distributions de classes des classifications sur T32NPL

L'objectif de cette section est de comparer en effectuant la moyenne des scores calculés au sein de grandes régions extraites des classifications des différents mois et de l'année complète 2018, de la zone d'intérêt T32NPL.

Le Tableau 4.12 présente les moyennes des scores calculés au sein de cellules de taille 200 pixels extraites des classifications supervisées de séries temporelles d'images optiques Sentinel-2_L2A des mois et de l'année complète 2018 et de la VT utilisant la légende à 9 classes, de la zone d'intérêt T32NPL. On peut globalement constater de faibles valeurs des scores de comparaison par région des classifications mensuelles et annuelle et la VT. **La classification du mois d'août est encore plus différente des autres classifications avec des scores les plus élevées de 0,51 à 0,92. De même, les mois d'avril et juillet rejoignent ici le mois d'août en étant respectivement très et assez différents des autres classifications avec des scores de 0,49 à 0,78 pour le mois d'avril et de 0,45 à 0,62 pour le mois de juillet.** Ceci explique les mauvaises qualités des séries d'images Sentinel-2 pendant les mois d'avril, juillet et d'août. Ici, aucune classification ne donne des scores identiques en comparant avec quatre autres classifications à la fois. Par contre, les quatre groupes de classifications mensuelles et annuelle (mai, juin et septembre); (septembre, novembre et décembre); (mai, juin et septembre) et

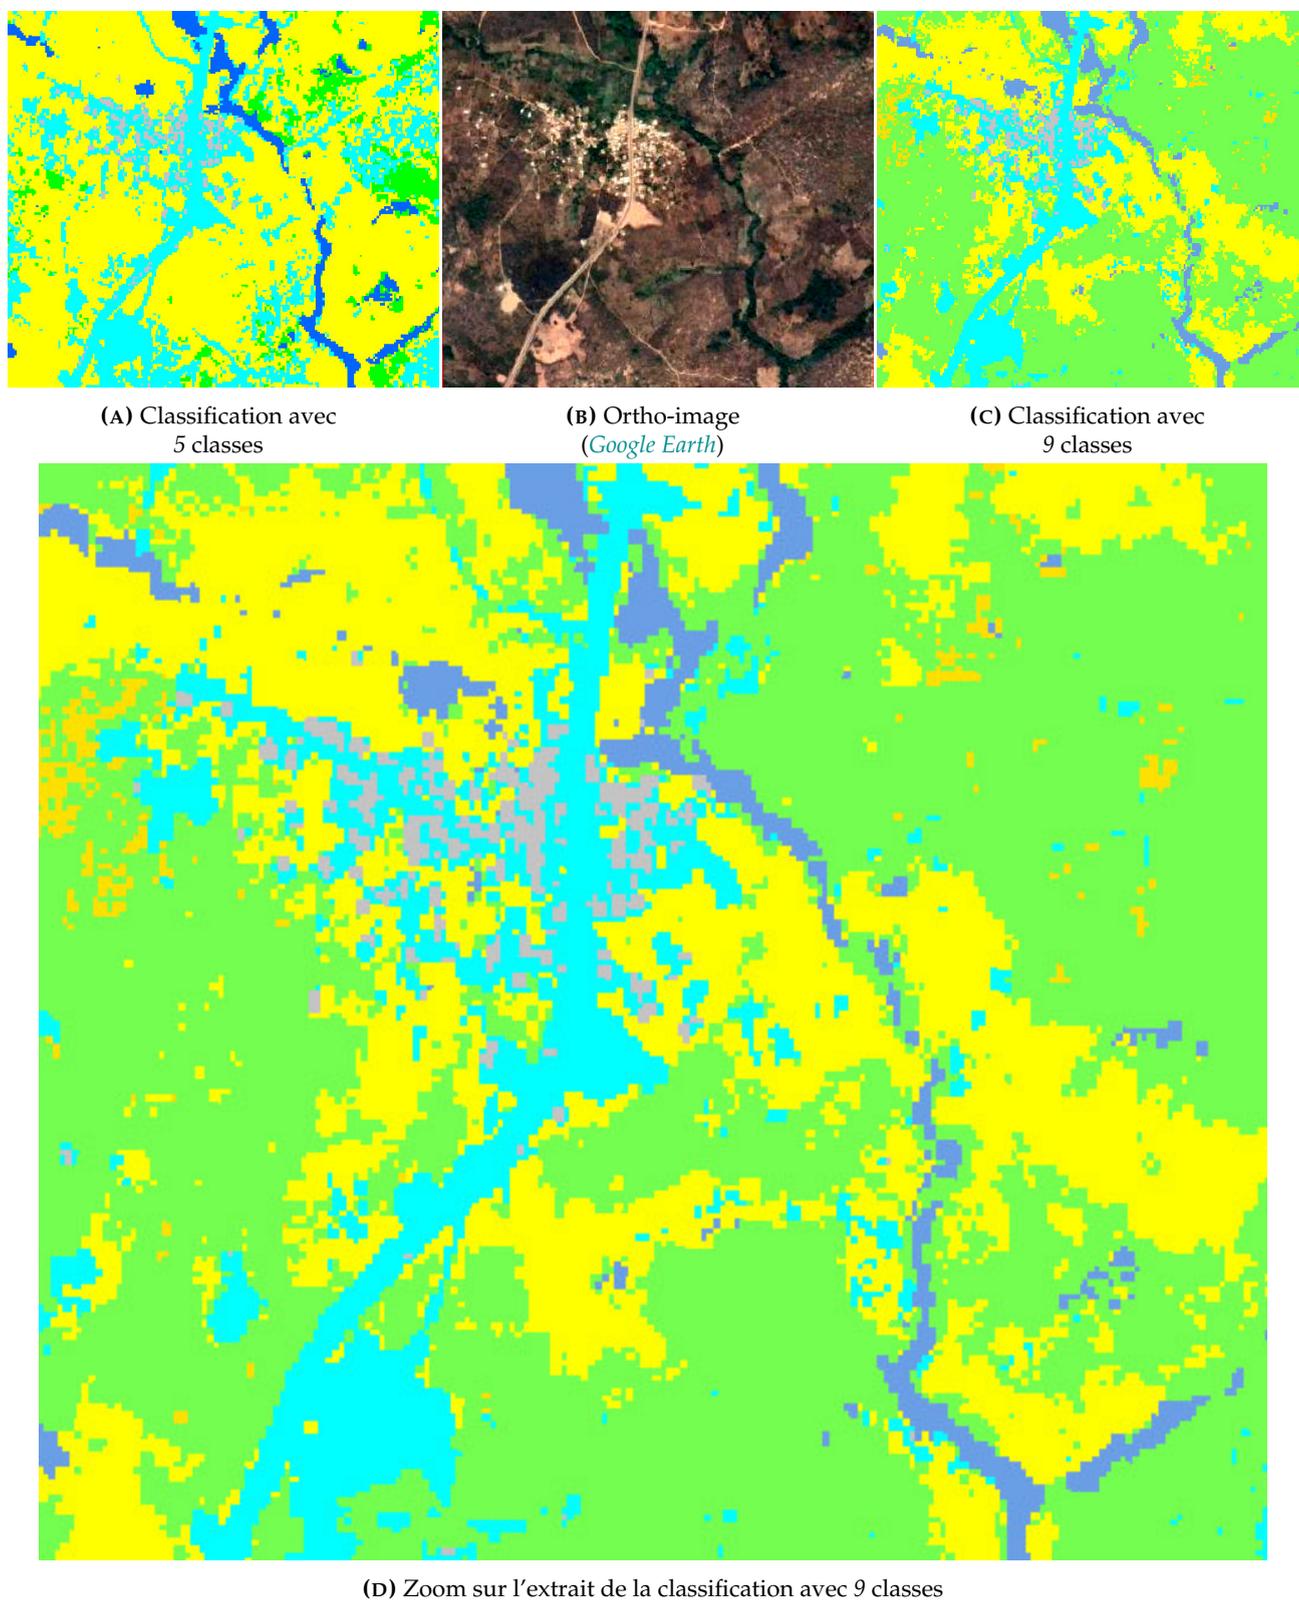


FIG. 4.26 – Extraits de l'ortho-image et des classifications de séries temporelles d'images optiques Sentinel-2_L2A avec les légendes à 5 : ■ : VGT; ■ : AGR; ■ : EAU; ■ : RTE; ■ : BTM et 9 : ■ : FRT; ■ : PRA; ■ : ARB; ■ : AGR; ■ : SFE; ■ : ZHU; ■ : RIV; ■ : RTE; ■ : BTM classes, d'une zone urbaine sur la zone d'intérêt T32NPL.

TAB. 4.11 – Coefficients Kappa (K) et F-Score moyen (FS) obtenus au terme de la comparaison pixel à pixel des classifications mensuelles et annuelle de séries temporelles d'images optiques Sentinel-2_L2A et de la VT avec la légende à 9 classes de la zone d'intérêt T32NPL.

	jan.		fév.		mar.		avr.		mai		juin		juil.		août.		sep.		oct.		nov.		déc.		2018		VT	
	K	FS	K	FS	K	FS	K	FS	K	FS	K	FS	K	FS	K	FS	K	FS	K	FS	K	FS	K	FS	K	FS	K	FS
<i>L2A</i>																												
janvier	1,0	100,0	0,6	44,9	0,5	33,9	0,2	18,6	0,4	28,8	0,4	28,8	0,3	25,2	0,1	16,1	0,4	28,0	0,3	24,0	0,5	36,8	0,6	42,1	0,6	44,1	0,5	29,1
février	0,6	44,9	1,0	100,0	0,5	33,7	0,2	18,1	0,4	28,7	0,4	30,7	0,3	25,1	0,1	15,4	0,4	29,2	0,3	24,5	0,5	37,7	0,6	43,4	0,7	46,6	0,5	31,8
mars	0,5	33,9	0,5	33,7	1,0	100,0	0,1	16,7	0,4	26,9	0,4	28,2	0,2	23,3	0,1	14,6	0,3	25,5	0,2	21,9	0,4	30,3	0,5	33,0	0,5	38,5	0,4	26,6
avril	0,2	18,6	0,2	18,1	0,1	16,7	1,0	100,0	0,1	16,3	0,1	16,4	0,1	20,6	0,1	15,8	0,1	15,8	0,1	13,2	0,1	17,9	0,2	17,8	0,2	18,6	0,1	13,5
mai	0,4	28,8	0,4	28,7	0,4	26,9	0,1	16,3	1,0	100,0	0,4	26,8	0,2	23,5	0,1	14,8	0,3	24,6	0,2	20,4	0,4	28,4	0,4	28,8	0,4	32,4	0,4	23,4
juin	0,4	28,8	0,4	30,7	0,4	28,2	0,1	16,4	0,4	26,8	1,0	100,0	0,3	25,3	0,1	14,0	0,3	25,6	0,2	20,9	0,4	28,5	0,4	31,1	0,5	35,0	0,4	25,6
juillet	0,3	25,2	0,3	25,1	0,2	23,2	0,1	20,6	0,2	23,5	0,3	25,3	1,0	100,0	0,1	18,7	0,2	21,9	0,1	18,1	0,3	26,1	0,3	24,7	0,3	29,1	0,2	20,4
août	0,1	16,1	0,1	15,4	0,1	14,6	0,1	14,6	0,1	14,8	0,1	14,0	0,1	18,7	1,0	100,0	0,1	14,2	0,1	12,1	0,1	15,9	0,1	15,8	0,1	16,6	0,1	13,2
septembre	0,4	28,0	0,4	29,2	0,3	25,5	0,1	15,8	0,3	24,6	0,3	25,6	0,2	21,9	0,1	14,2	1,0	100,0	0,2	20,8	0,4	28,2	0,4	29,3	0,4	32,2	0,4	23,8
octobre	0,3	24,0	0,3	24,5	0,2	21,9	0,1	13,2	0,2	20,4	0,2	20,9	0,1	18,1	0,1	12,1	0,2	20,8	1,0	100,0	0,2	24,6	0,3	23,8	0,3	27,1	0,3	22,1
novembre	0,5	36,8	0,5	37,7	0,4	30,3	0,1	17,9	0,4	28,4	0,4	28,5	0,3	26,1	0,1	15,9	0,4	28,2	0,2	24,6	1,0	100,0	0,6	39,8	0,6	42,2	0,4	27,6
décembre	0,6	42,1	0,6	43,4	0,5	33,0	0,2	17,8	0,4	28,8	0,4	31,1	0,3	24,7	0,1	15,8	0,4	29,3	0,3	23,8	0,6	39,8	1,0	100,0	0,7	43,8	0,5	29,6
2018	0,6	44,1	0,7	46,5	0,5	38,5	0,2	18,6	0,4	32,4	0,5	35,0	0,3	29,1	0,1	16,6	0,4	32,2	0,3	27,1	0,6	42,2	0,7	43,8	1,0	100,0	0,5	43,0
VT	0,5	29,1	0,5	31,8	0,4	26,6	0,1	13,5	0,4	23,4	0,4	25,6	0,2	20,4	0,1	13,2	0,3	23,8	0,3	22,1	0,4	27,6	0,5	29,6	0,5	43,0	1,0	100,0

k : nombre de classes. VT : vérité terrain.

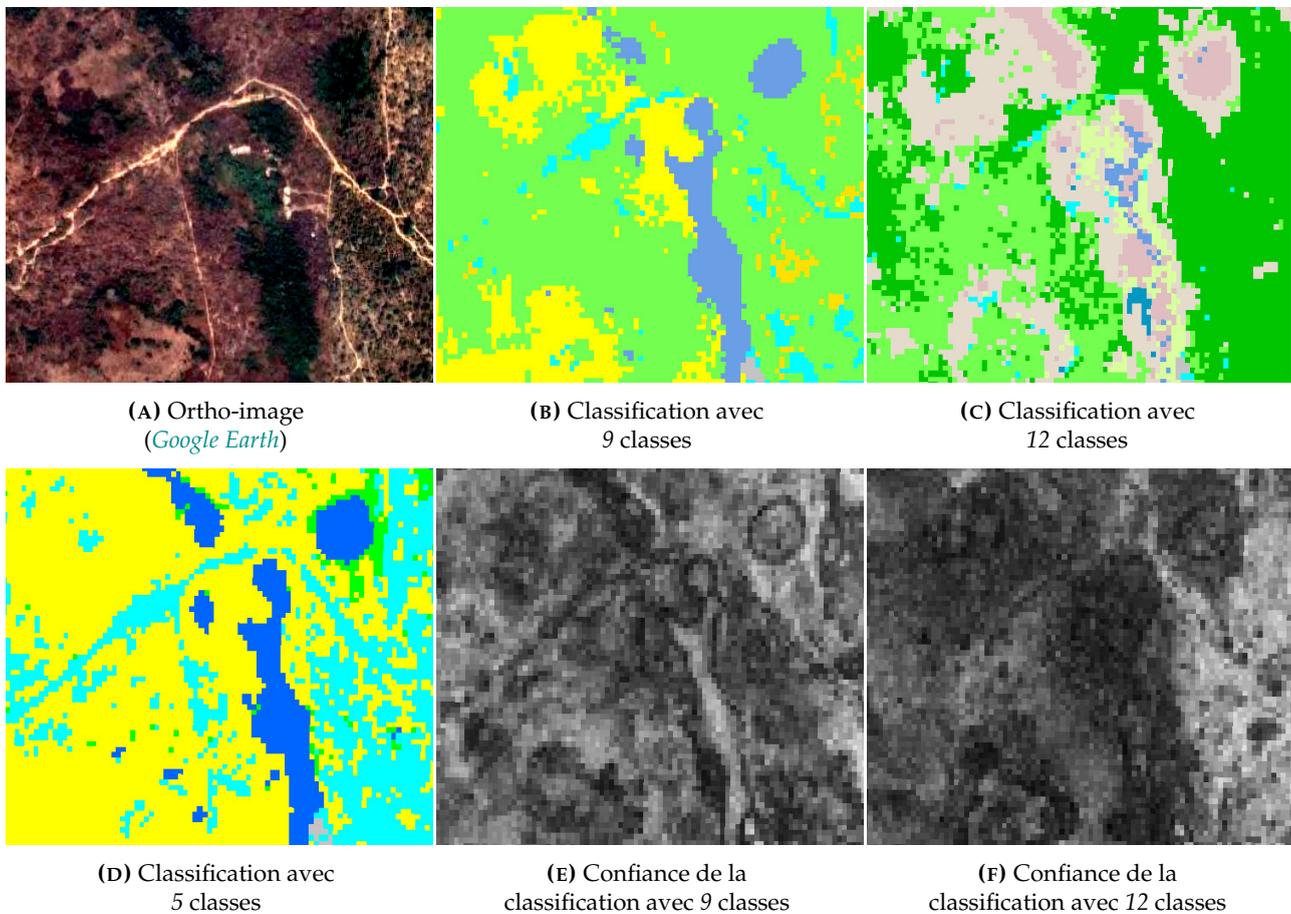


FIG. 4.27 – Extraits de l’ortho-image et des classifications et des confiances de classifications de séries temporelles d’images optiques Sentinel-2_L2A avec les légendes à 5 et 9 et 12 classes, de petites classes locales sur la zone d’intérêt T32NPL.

(mai, novembre et 2018) se rapprochent des quatre classifications des mois de janvier ; juin ; novembre et mars avec de faibles scores de 0,23 ; 0,21 ; 0,21 et 0,2 respectivement.

4.5.2.6 Influence de la nomenclature et de la dimension temporelle des données sur les classifications supervisées de la zone d’intérêt T32NPL

La légende et la période de classification (mensuelles ou annuelle) des données satellitaires sont susceptibles de modifier les performances de classification. On obtient les résultats les plus forts des classifications de l’année complète 2018 pour les trois légendes si l’on considère les FS. Cependant, l’analyse des K révèle que les meilleurs résultats sont généralement obtenus pour les légendes à 9 et 12 classes. Bien que les résultats soient moins bons pour la légende à 12 classes, l’amélioration obtenue en fusionnant les classes d’OCS n’est pas si importante. En parallèle, la période de classification des images (mensuelles ou annuelle) peut également modifier les performances. Ainsi, la Section 4.5.2.1 montre qu’on obtient les résultats les plus forts pour les trois légendes, des classifications de la série annuelle complète (2018) si l’on considère les FS. Par contre, l’analyse des K révèle que les meilleurs résultats sont généralement obtenus pour la légende à 5 classes, de la classification du mois de février. Bien que les résultats des classifications soient moins bons pour les trois légendes avec la série d’août et pour la légende à 12 classes avec la série d’avril si l’on considère les FS d’une part et pour les légendes à 5 et 12 classes avec la série d’août et pour la légende à 9 classes avec la série d’avril si l’on considère

<i>L2A</i>	jan.	fév.	mar.	avr.	mai	juin	juil.	août.	sep.	oct.	nov.	déc.	2018	<i>VT</i>
janvier	0.00	0.16	0.21	0.68	0.23	0.23	0.48	0.81	0.23	0.33	0.19	0.19	0.17	0.30
février	0.16	0.00	0.22	0.70	0.25	0.23	0.50	0.83	0.25	0.37	0.18	0.14	0.13	0.31
mars	0.21	0.22	0.00	0.67	0.20	0.18	0.47	0.81	0.22	0.30	0.20	0.21	0.20	0.29
avril	0.68	0.70	0.67	0.00	0.65	0.65	0.49	0.51	0.63	0.73	0.66	0.71	0.72	0.78
mai	0.23	0.25	0.20	0.65	0.00	0.19	0.46	0.77	0.19	0.30	0.21	0.24	0.25	0.33
juin	0.23	0.23	0.18	0.65	0.19	0.00	0.45	0.80	0.21	0.31	0.21	0.21	0.23	0.30
juillet	0.48	0.50	0.47	0.49	0.46	0.45	0.00	0.59	0.46	0.59	0.45	0.45	0.51	0.62
août	0.81	0.83	0.81	0.51	0.77	0.80	0.59	0.00	0.77	0.86	0.79	0.83	0.85	0.92
septembre	0.23	0.25	0.22	0.63	0.19	0.21	0.46	0.77	0.00	0.31	0.21	0.24	0.25	0.31
octobre	0.33	0.37	0.30	0.73	0.30	0.31	0.59	0.86	0.31	0.00	0.35	0.38	0.37	0.31
novembre	0.19	0.18	0.20	0.66	0.21	0.21	0.45	0.79	0.21	0.35	0.00	0.16	0.17	0.33
décembre	0.19	0.14	0.21	0.71	0.24	0.21	0.51	0.83	0.24	0.38	0.16	0.00	0.14	0.31
2018	0.17	0.13	0.20	0.72	0.25	0.23	0.50	0.85	0.25	0.37	0.17	0.14	0.00	0.27
<i>VT</i>	0.30	0.31	0.29	0.78	0.33	0.30	0.62	0.92	0.31	0.31	0.33	0.31	0.27	0.00

TAB. 4.12 – Moyennes des distances entre les histogrammes calculées au sein de cellules de taille 200 pixels extraites des classifications mensuelles et annuelle de séries temporelles d'images optiques Sentinel-2_L2A et de la vérité terrain (*VT*) avec la légende à 9 classes, de la zone d'intérêt T32NPL.

les K d'autre part, la classification de la série annuelle complète n'est pas si importante étant donné que les meilleurs résultats sont par ailleurs obtenus pour la légende à 5 classes, des classifications des mois d'octobre et décembre.

4.6 Stabilité du *Random Forest* sur l'étendue d'un bloc de tuiles Sentinel-2

On évalue ici performances de classification sur de grandes étendues. Ainsi, la deuxième stratégie (*STR2*) de cette thèse est mise en oeuvre sur toute l'étendue de la zone d'étude *ZONE1*. Ainsi, différents couples de blocs de tuiles adjacents sont préalablement constitués. Chaque bloc peut correspondre à une tuile ou un groupe d'au moins deux et d'au plus $(N - 1)$ tuiles avec N : nombre total de tuiles sur la zone d'étude. Ici, il a été choisi de travailler avec des blocs d'au moins trois tuiles Sentinel-2 sur la zone d'étude *ZONE1* pour favoriser les problèmes équilibrés à l'apprentissage. Pour les classes sous-représentées, le nombre maximal d'échantillons d'apprentissage disponible est utilisé. Aucune stratégie de sur- ou sous-échantillonnage n'est utilisée.

Dans cette partie, les résultats de la classification sont analysés pour les différentes légendes. Au cours des travaux, les performances de classification sont calculées en une seule exécution utilisant différentes tailles de zone d'apprentissage en fonction des blocs de tuiles, puis discutées sur les résultats de différents modèles de classification de l'OCS de la zone d'étude *ZONE1*. Enfin, l'influence de la nomenclature des données de référence et de la dimension temporelle des images satellitaires sur ces performances de classification, est de nouveau étudiée pour chaque légende.

4.6.1 Évaluation quantitative avec différents modèles sur la zone d'étude *ZONE1*

Les Figures 4.28 et 4.29 présentent les métriques de qualité globale pour l'année complète 2018 pour les quatre modèles de classification par entraînement du classifieur sur 3 (Modèle1), 4 (Modèle2), 5 (Modèle3) ou 6 (Modèle4) tuiles et les trois légendes. Quelle que soit la légende utilisée, les valeurs de FS et de K sont toujours variables et faibles ($0,31 < FS < 0,38$ et $0,22 < K < 0,37$). **Les résultats les plus forts sont associés aux classifications du Modèle3 pour les légendes à 5 et 9 classes et du Modèle4 pour la légende à 12 classes si l'on considère les FS et aux classifications du Modèle3 pour les légendes à 5 et 9 classes et du Modèle1 pour la légende à 12 classes si l'on considère les K.** Au contraire, les résultats les plus faibles sont associés aux classifications des Modèle4, Modèle1 et Modèle2 pour les légendes à 5, 12 et 9 classes si l'on considère les FS et aux classifications des Modèle4, Modèle2 et Modèle3 pour les légendes à 5, 9 et 12 classes si l'on considère les K respectivement. Ces résultats sont en accord avec ceux obtenus dans la littérature, qui montrent l'intérêt d'entraîner le classifieur sur une zone de plus grande étendue comme c'est le cas avec le Modèle4 en présence d'une nomenclature bien détaillée comme la légende à 12 classes afin d'améliorer les résultats de la classification et permettre ainsi une meilleure discrimination des classes d'OCS telles que les classes VNC et VHB ou encore les classes FOU et FFE.

Les Figures 4.30, 4.31 et 4.32 présentent les métriques de qualité par classe. L'utilisation des légendes à 5 et 9 classes permet d'améliorer les classifications dans un premier temps, des Modèle2 des classes VGT (FS (VGT) $\simeq 0,75$) et EAU (FS (EAU) $\simeq 0,45$) d'une part et Modèle3 des classes AGR (FS (AGR) $\simeq 0,67$); RTE (FS (RTE) $\simeq 0,02$) et BTM (FS (BTM) $\simeq 0,04$) d'autre part pour la légende à 5 classes et dans un deuxième temps, des Modèle4 des classes FRT (FS (FRT) $\simeq 0,2$) et AGR (FS (AGR) $\simeq 0,56$) puis Modèle3 des classes PRA (FS (PRA) $\simeq 0,74$); ARB (FS (ARB) $\simeq 0,22$); ZHU (FS (ZHU) $\simeq 0,24$) et RIV

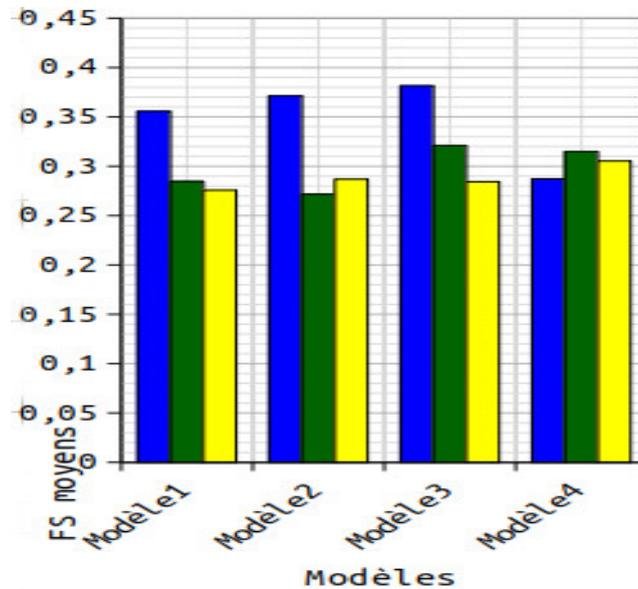


FIG. 4.28 – F-Scores moyens de la classification supervisée de la série annuelle complète d’images optiques Sentinel-2_L2A avec les différents modèles et les légendes à 5 et 9 et 12 classes de la zone d’étude ZONE1.

(FS (RIV) $\simeq 0,18$) et enfin Modèle1 des classes SFE (FS (SFE) $\simeq 0,96$) et BTM (FS (BTM) $\simeq 0,04$) pour la légende à 9 classes. Dans un troisième temps, l’utilisation de la légende à 12 classes permet également d’améliorer les classifications des Modèle4 des classes VHB (FS (VHB) $\simeq 0,32$) et ZHU (FS (ZHU) $\simeq 0,54$) puis Modèle1 des classes VNC (FS (VNC) $\simeq 0,28$); FOU (FS (FOU) $\simeq 0,51$); TCU (FS (TCU) $\simeq 0,48$) et ZHH (FS (ZHH) $\simeq 0,24$) et enfin Modèle2 des classes FFE (FS (FFE) $\simeq 0,34$); ARB (FS (ARB) $\simeq 0,31$); SFE (FS (SFE) $\simeq 0,8$) et RIV (FS (RIV) $\simeq 0,1$).

La fusion des *BDs* d’*OSM*, de l’*INC* et de *GLC* offre également de bonnes performances aux classifications de tous les modèles. Par contre, ces classifications sont de moins bonne qualité comparativement à celles correspondant aux légendes à 5 et 9 classes. Ce résultat montre que l’ajout de *BDs* complexifie l’apprentissage du classifieur et dégrade ainsi les performances des classifications des différents modèles. C’est ainsi que **les classes RTE et BTM ont malgré tout pu être détectées en trace dans les classifications annuelles des différents modèles pour les légendes à 9 et 12 classes** étant donné que toutes les séries mensuelles sont ici combinées.

La fusion des classes FRT; PRA et ARB dans la légende à 9 classes en la classe VGT de la légende à 5 classes offre des résultats contrastés. En effet, l’utilisation de la classe VGT augmente grandement les performances de la classification annuelle du Modèle3 (FS = 0,38; PU (VGT) $\simeq 0,63$) pour la légende à 5 classes, alors que le FS est de 0,32 lorsque les classes FRT; PRA et ARB sont considérées indépendamment (PU (FRT) $\simeq 0,03$; PU (PRA) $\simeq 0,8$ et PU (ARB) $\simeq 0,14$) pour la légende à 9 classes. Malgré une augmentation de leurs valeurs, les FS et les PU demeurent cependant de moins bonne qualité pour les classifications des différents modèles avec les images optiques Sentinel-2 seules. **La fusion des classes FRT; PRA et ARB n’est pas un choix suffisant et pertinent, comme en attestent les valeurs faibles de FS des classifications annuelles des différents modèles pour la légende à 5 classes.** Dans ce cas, la combinaison des séries mensuelles ne permet pas d’outrepasser complètement le bruit d’étiquetage présent dans la classification utilisant uniquement les images optiques Sentinel-2 avec la fusion des classes d’*OCS*.

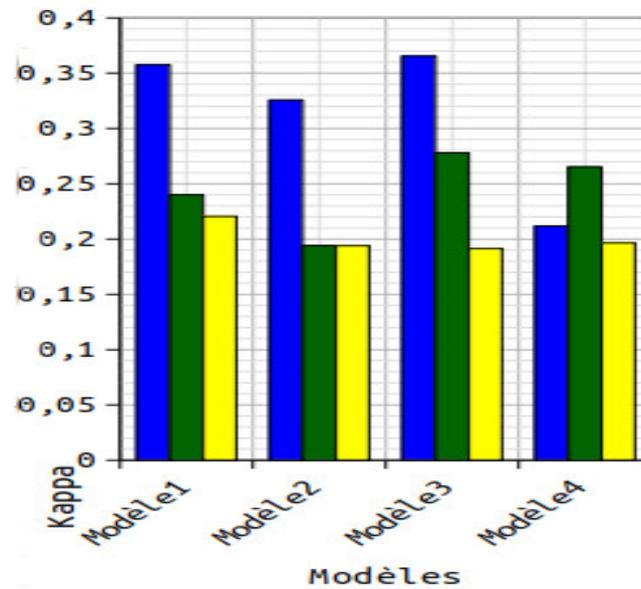


FIG. 4.29 – Coefficients Kappa (K) de la classification annuelle (2018) pour les mêmes modèles et légendes que les FS dans la Figure 4.30.

Les bonnes performances des classifications du Modèle4 des classes FRT et PRA pour la légende à 9 classes de même que celles des classes VNC et VHB pour la légende à 12 classes sont dues à un meilleur apprentissage du classifieur. En effet, **le fait de contraindre l'entraînement du classifieur sur une zone d'étendue plus grande (Modèle4) permet d'améliorer le modèle de classification en aidant le classifieur dans la prise d'une décision fiable au cours de l'étape d'apprentissage.** Ceci constitue une limite pour les classifications mais également pour l'obtention au terme de l'étape d'apprentissage, d'un modèle de classification ayant les caractéristiques de la zone à classifier représentée en contours de parcellaire correspondant à une unité simple d'OCS. De différentes classes d'OCS contiguës peuvent être regroupées dans une seule classe et une classe hétérogène peut correspondre à plusieurs autres classes d'OCS. Ces limites sont liées au fait de se fonder sur des données de référence imparfaites.

4.6.1.1 Cas particulier avec le Modèle4

Les Figures 4.33 et 4.34 présentent les métriques de qualité globale pour 6 tuiles Sentinel-2 et les trois légendes. Quelle que soit la légende, les valeurs de FS et de K pour les images optiques sont variables et faibles ($0,3 < FS < 0,32$ et $0,19 < K < 0,27$). **Les résultats les plus forts sont associés aux classifications du mois de juillet pour la légende à 5 classes et de l'année complète pour les légendes à 9 et 12 classes si l'on considère les FS et aux classifications du mois de mai pour la légende à 5 classes et de l'année complète pour les légendes à 9 et 12 classes si l'on considère les K.** Au contraire, les résultats les plus faibles sont associés aux mois de juillet pour les légendes à 9 et 12 classes et mars pour la légende à 5 classes si l'on considère les FS et aux mois de mars, mai et septembre pour les légendes à 5, 9 et 12 classes respectivement si l'on considère les K. Ces résultats corroborent ceux obtenus précédemment dans la classification annuelle du Modèle4 pour la légende à 12 classes. En effet, le Modèle4 permet d'améliorer les résultats en travaillant avec un grand nombre d'échantillons d'apprentissage représenté ici par la fusion des BDs en 9 ou 12 classes d'OCS. Par contre, on peut également remarquer de faibles résultats en utilisant quelques séries mensuelles comme celles de mai, juillet ou septembre avec les deux précédentes légendes. Ceci provient de la mauvaise qualité des

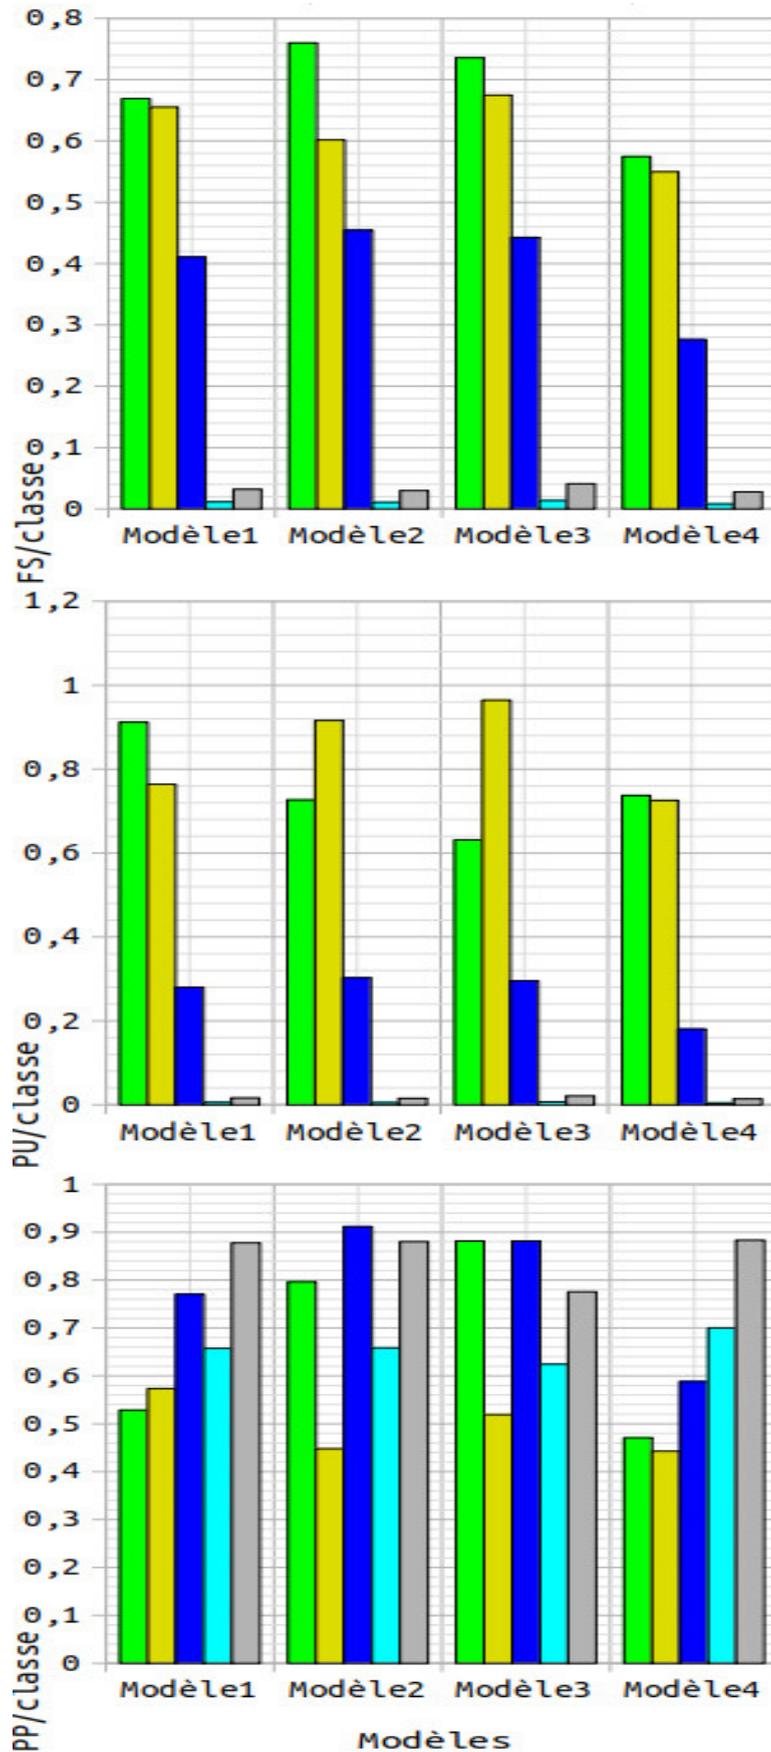


FIG. 4.30 – F-Scores et précision utilisateur et précision producteur par classe de la classification supervisée de la série annuelle complète d’images optiques Sentinel-2_L2A avec les différents modèles et la légende à 5 classes : ■ : VGT; ■ : AGR; ■ : EAU; ■ : RTE; ■ : BTM de la zone d’étude ZONE1.

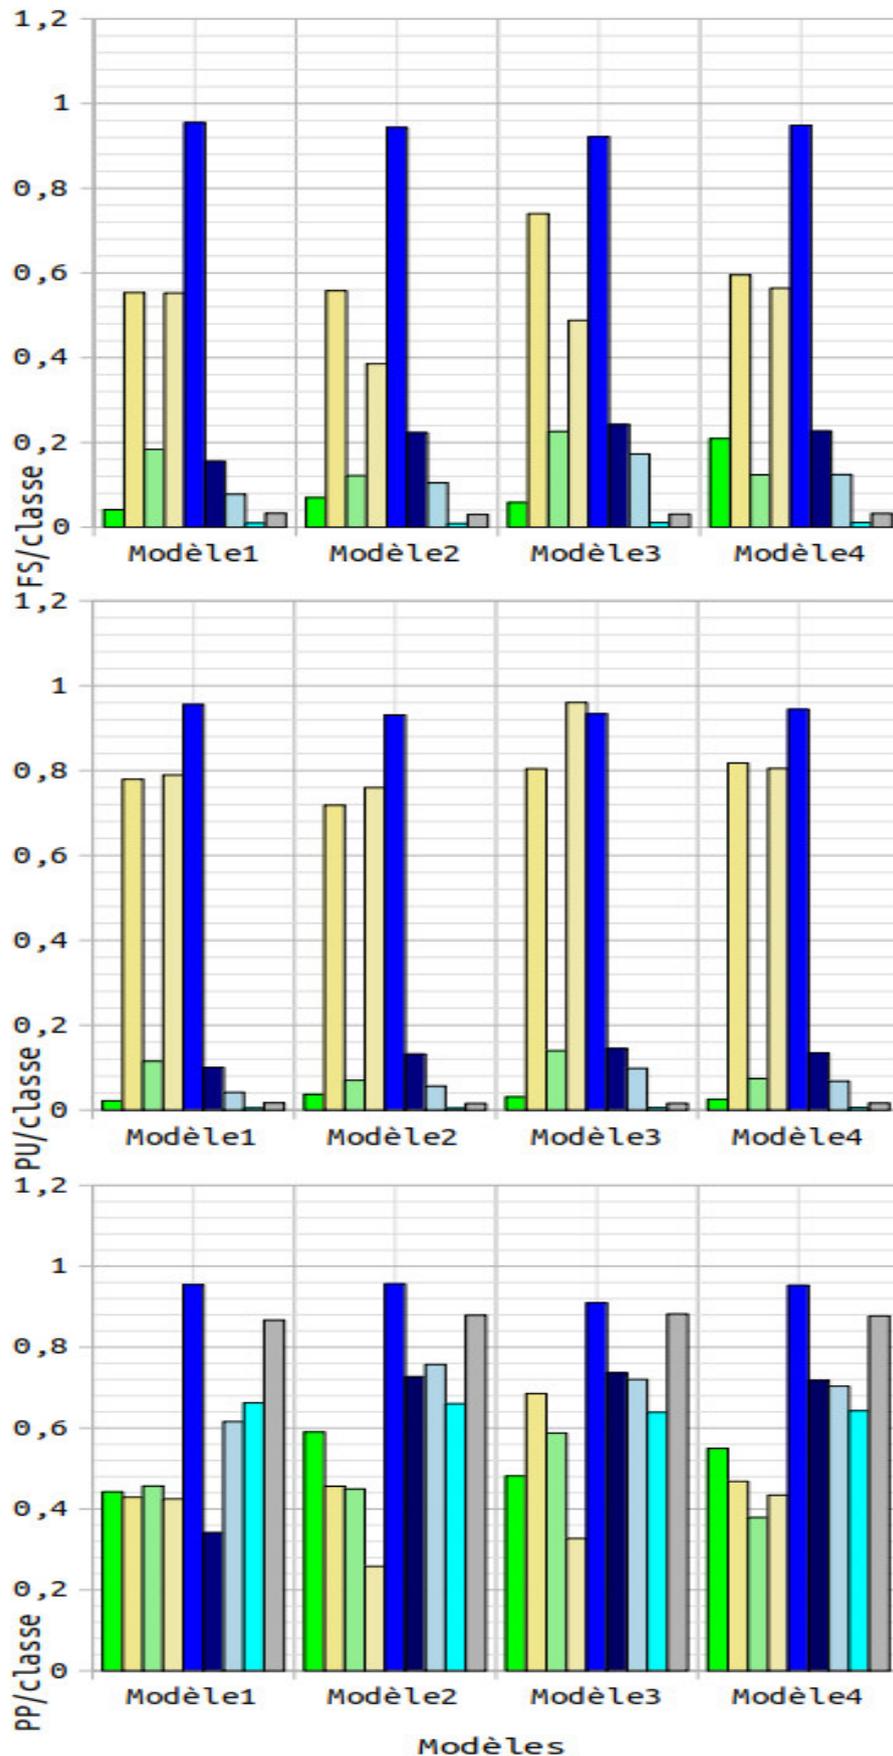


FIG. 4.31 – F-Scores et précision utilisateur et précision producteur par classe de la classification supervisée de la série annuelle complète d’images optiques Sentinel-2_L2A avec les différents modèles et la légende à 9 classes : ■ : FRT ; ■ : PRA ; ■ : ARB ; ■ : AGR ; ■ : SFE ; ■ : ZHU ; ■ : RIV ; ■ : RTE ; ■ : BTM de la zone d’étude ZONE1.

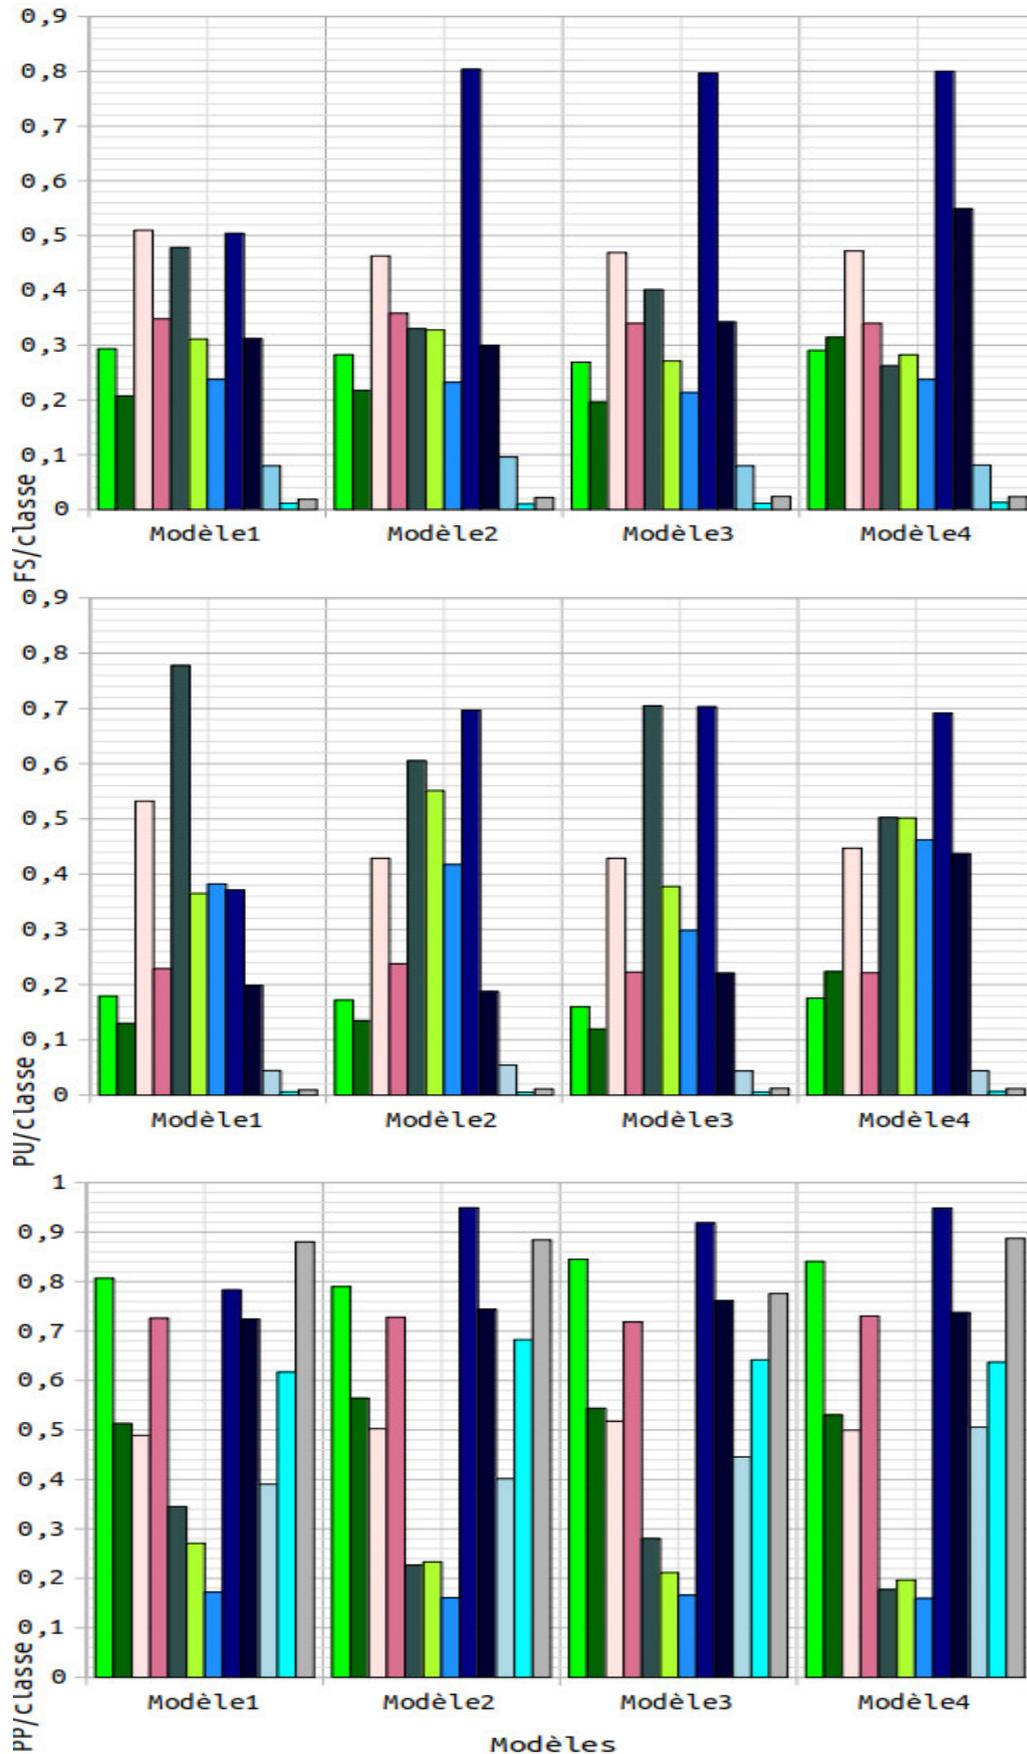


FIG. 4.32 – F-Scores et précision utilisateur et précision producteur par classe de la classification supervisée de la série annuelle complète d’images optiques Sentinel-2_L2A avec les différents modèles et la légende à 12 classes : ■ : VNC; ■ : VHB; ■ : FOU; ■ : FFE; ■ : TCU; ■ : ARB; ■ : ZHH; ■ : SFE; ■ : ZHU; ■ : RIV; ■ : RTE; ■ : BTM de la zone d’étude ZONE1.

images optiques comportant des résidus de nuages sur cette zone occasionnant des erreurs comme pour les classes VNC et VHB ainsi que des classes FOU et FFE pour la légende à 12 classes qui se trouvent mieux discriminées dans les classifications de l'année complète.

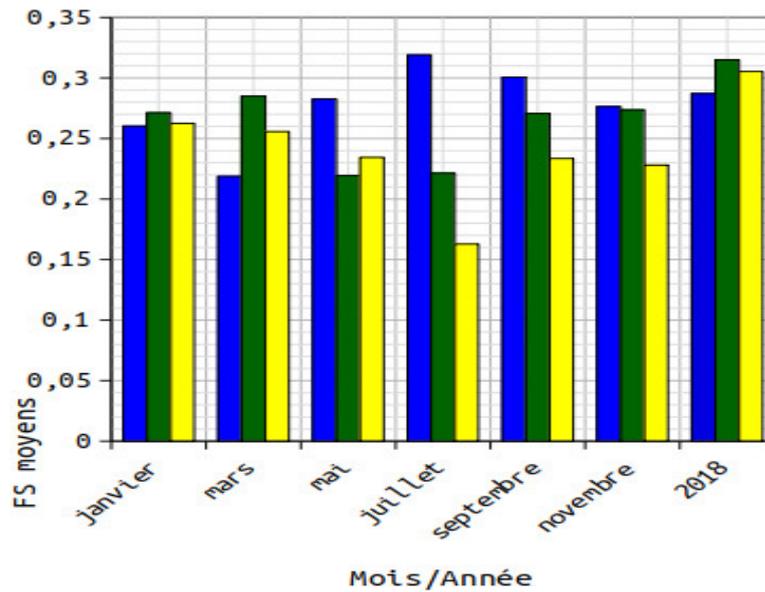


FIG. 4.33 – F-Scores moyens des classifications supervisées de séries temporelles d'images optiques Sentinel-2_L2A avec le Modèle4 et les légendes à 5 et 9 et 12 classes de la zone d'étude ZONE1.

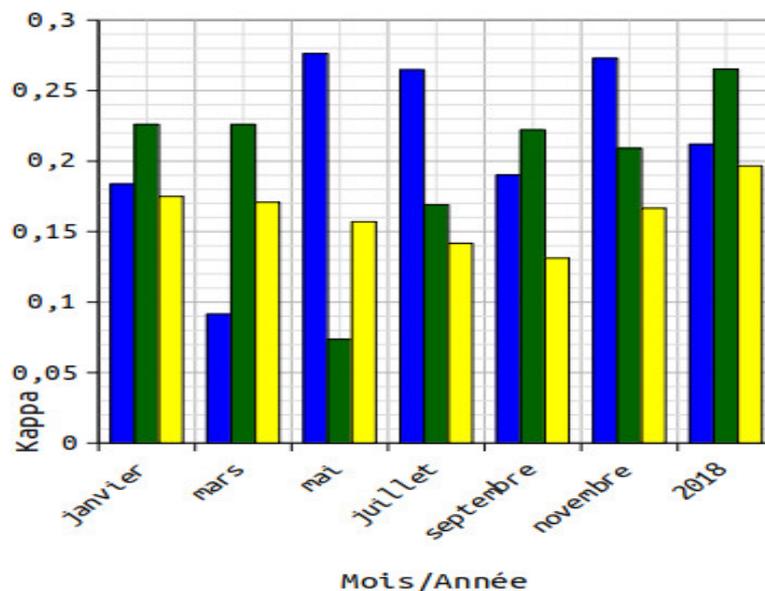


FIG. 4.34 – Coefficients Kappa des modèles et légendes de la Figure 4.33.

Les Figures 4.35, 4.36 et 4.37 présentent les métriques de qualité par classe. L'utilisation des légendes à 5 et 9 classes permet d'améliorer la classification annuelle de la classe BTM (FS (BTM) $\simeq 0,025$) seule pour la légende à 5 classes puis des classes FRT (FS (FRT) $\simeq 0,25$); AGR (FS (AGR) $\simeq 0,56$); SFE (FS (SFE) $\simeq 0,95$) et BTM (FS (BTM) $\simeq 0,03$) pour la légende à 9 classes. De plus, les classes VGT (FS (VGT) $\simeq 0,75$) est améliorée dans la classification du mois de novembre; AGR (FS (AGR) $\simeq 0,57$) et RTE (FS (RTE) $\simeq 0,02$) sont améliorées dans la classification du mois de juillet et EAU (FS (EAU) $\simeq 0,41$) est

améliorée pour le mois de septembre pour la légende à 5 classes tandis que les classes PRA (FS (PRA) $\simeq 0,76$) et ARB (FS (ARB) $\simeq 0,15$) sont améliorées dans la classification du mois de mars et ZHU (FS (ZHU) $\simeq 0,27$) et RIV (FS (RIV) $\simeq 0,19$) sont améliorées dans la classification du mois de septembre pour la légende à 9 classes. L'utilisation de la légende à 12 classes permet également d'améliorer les classes VHB; FOU; FFE et ZHU et des mois de janvier des classes VNC (FS (VNC) $\simeq 0,3$) et SFE (FS (SFE) $\simeq 0,81$), novembre des classes TCU (FS (TCU) $\simeq 0,46$) et SFE (FS (SFE) $\simeq 0,28$), mars de la classe ARB (FS (ARB) $\simeq 0,3$) et septembre de la classe RIV (FS (RIV) $\simeq 0,11$). **Les meilleurs résultats sont alors obtenus pour la légende à 9 classes, où le FS/classe atteint le FS (SFE) $\simeq 0,95$ de la classe SFE dans la classification annuelle et les précisions PU et PP atteignent respectivement la PU (SFE) $\simeq 0,96$ de la classe SFE dans la classification du mois de novembre et la PP (SFE) $\simeq 0,96$ de la classe SFE dans la classification de l'année complète.**

La fusion des *BDs* d'*OSM*, de l'*INC* et de *GLC* offre également de bonnes performances à l'ensemble des classifications mensuelles et annuelle du Modèle4. Par contre, ces classifications sont de moins bonne qualité pour la majorité des mois comparativement aux cas à 5 et 9 classes. Ce résultat montre que le fait d'ajouter de nouvelles *BDs* dégrade les performances des classifications mensuelles. C'est ainsi que **la classe RTE est détectée en trace dans l'ensemble des classifications mensuelles pour la légende à 9 classes tandis que les classes RTE et BTM sont détectées en trace dans toutes les classifications mensuelles pour la légende à 12 classes.** Par conséquent, il serait avantageux de combiner l'ensemble des séries mensuelles afin d'améliorer la classification individuelle des classes difficiles.

La fusion des classes FRT; PRA et ARB dans la légende à 9 classes en la classe VGT de la légende à 5 classes offre des résultats mitigés. En effet, l'utilisation de la classe VGT diminue les performances de la classification annuelle du Modèle4 (FS = $0,29$; PU (VGT) $\simeq 0,74$) pour la légende à 5 classes, alors que le FS est de $0,31$ lorsque les classes FRT; PRA et ARB sont considérées indépendamment (PU (FRT) $\simeq 0,03$; PU (PRA) $\simeq 0,82$ et PU (ARB) $\simeq 0,08$) pour la légende à 9 classes. La qualité des valeurs de FS et de PU s'améliore tout en restant de moins bonne qualité dans la classification annuelle du Modèle4 des classes d'*OCS* avec les images optiques Sentinel-2. Par conséquent, **la fusion des classes FRT; PRA et ARB est ici, un choix à prendre en considération même si elle n'est toutefois pas suffisante, comme en attestent les valeurs mitigées de FS de la classification annuelle pour la légende à 9 classes.** Dans ce cas, la fusion des classes d'*OCS* induit beaucoup plus de bruits que d'étiquettes utiles.

Les faibles performances des classes RTE et BTM dans les classifications mensuelles du Modèle4 utilisant les légendes à 9 et 12 classes sont directement liées aux faibles pourcentages de données de référence disponibles. Par ailleurs, les faibles résultats des classes FRT et ARB utilisant uniquement la légende à 9 classes est une conséquence de l'activité photosynthétique de ces classes d'*OCS* comme déjà décrit précédemment.

Afin de permettre l'analyse **des erreurs de classification utilisant le scénario STR2D sur la zone d'étude ZONE1 par rapport au scénario STR1 sur la zone d'intérêt T33PUL**, les Tableaux 4.13, 4.14 et 4.15 présentent les matrices de confusion avec les données optiques et le Modèle4 (*T33PTM-T33PUM-T33PUL-T33PTL-T33PTK-T33PUK*) utilisant respectivement les légendes à 5, 9 et 12 classes sur la ZONE1. Pour tous les cas, il existe des confusions récurrentes entre les classes.

Dans ces tableaux, les pixels identifiés en classe VGT se trouvent moins classifiés en AGR et le taux de FP, avec la classe AGR, baisse ici de $38,9\%$ à 25% avec l'utilisation de la zone d'étude ZONE1 entière

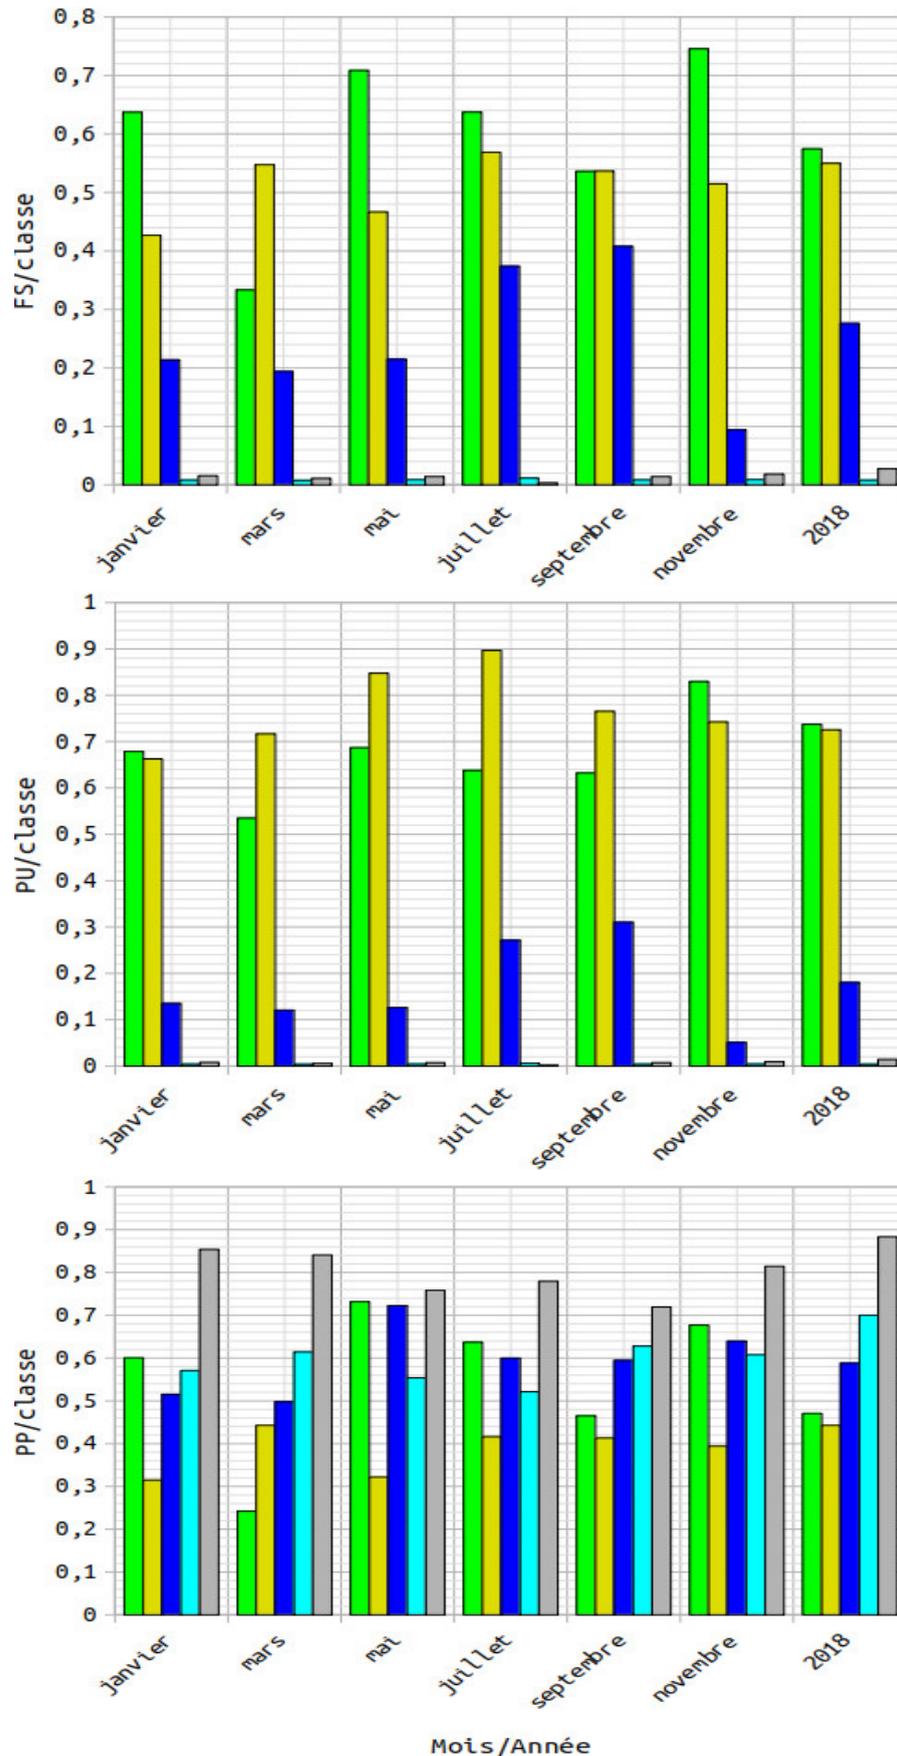


FIG. 4.35 – F-Scores et précision utilisateur et précision producteur par classe des classifications supervisées de séries temporelles d'images optiques Sentinel-2_L2A avec le Modèle4 et la légende à 5 classes : ■ : VGT; ■ : AGR; ■ : EAU; ■ : RTE; ■ : BTM de la zone d'étude ZONE1.

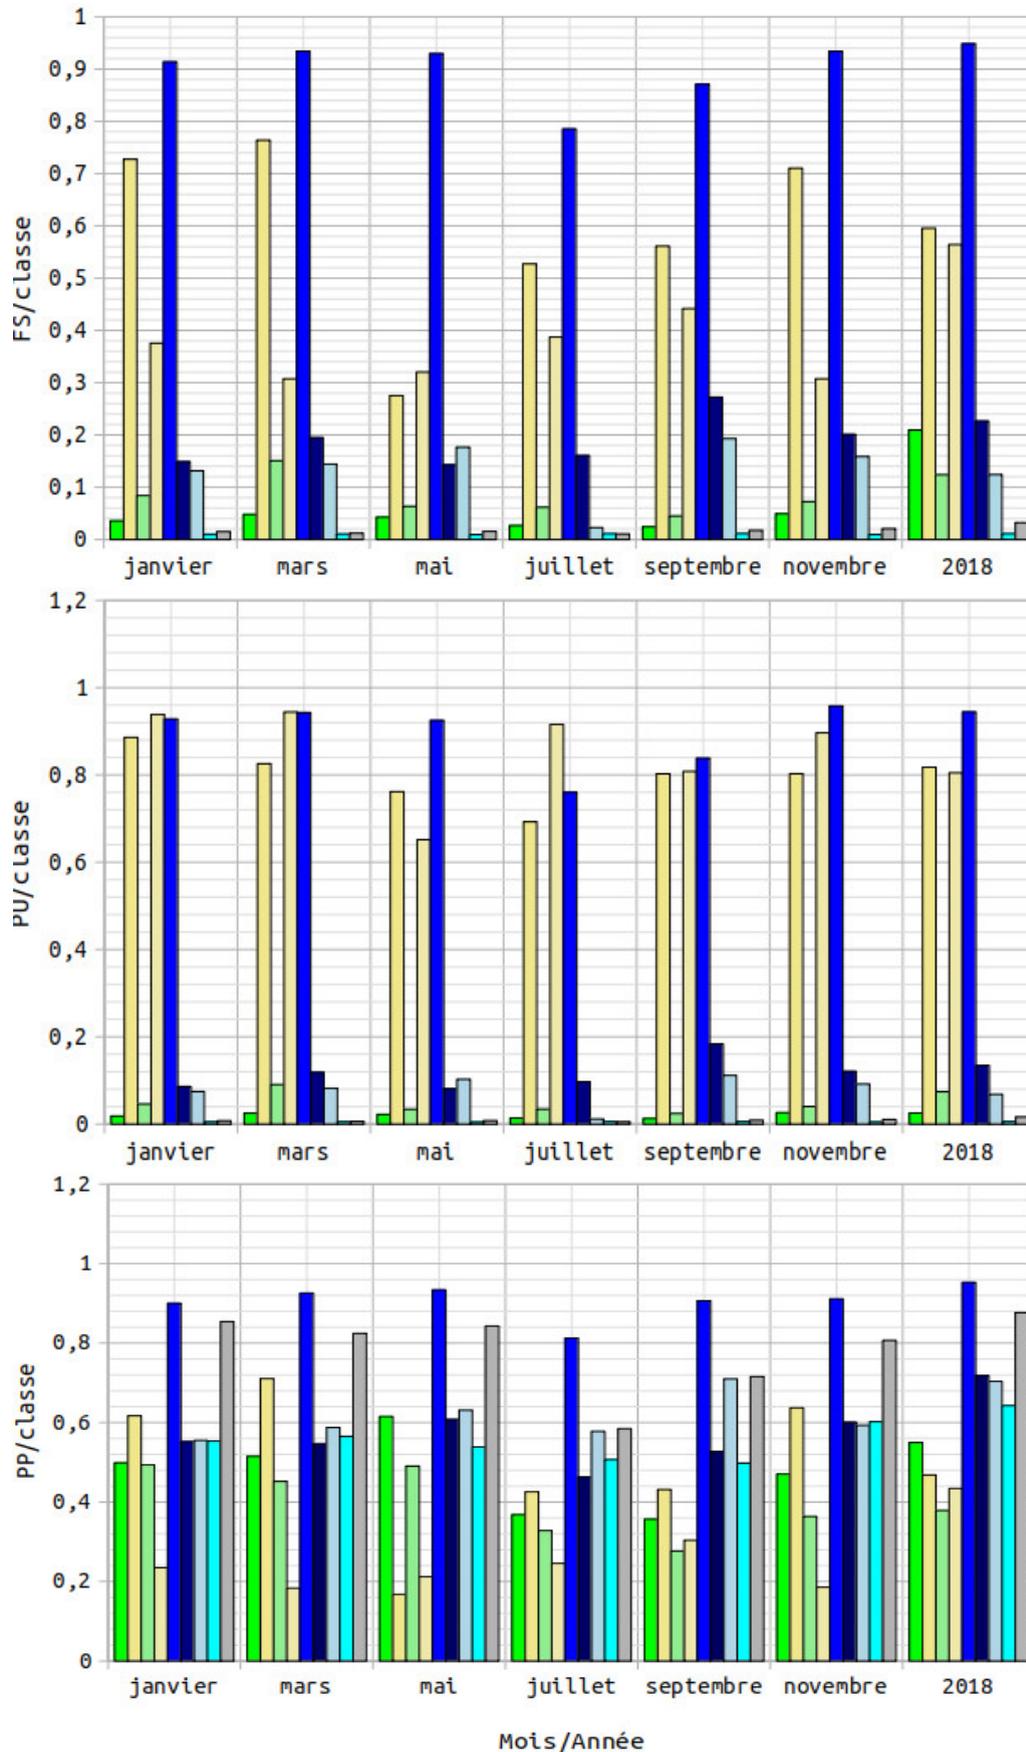


FIG. 4.36 – F-Scores et précision utilisateur et précision producteur par classe des classifications supervisées de séries temporelles d’images optiques Sentinel-2_L2A avec le Modèle4 et la légende à 9 classes : ■ : FRT ; ■ : PRA ; ■ : ARB ; ■ : AGR ; ■ : SFE ; ■ : ZHU ; ■ : RIV ; ■ : RTE ; ■ : BTM de la zone d’étude ZONE1.

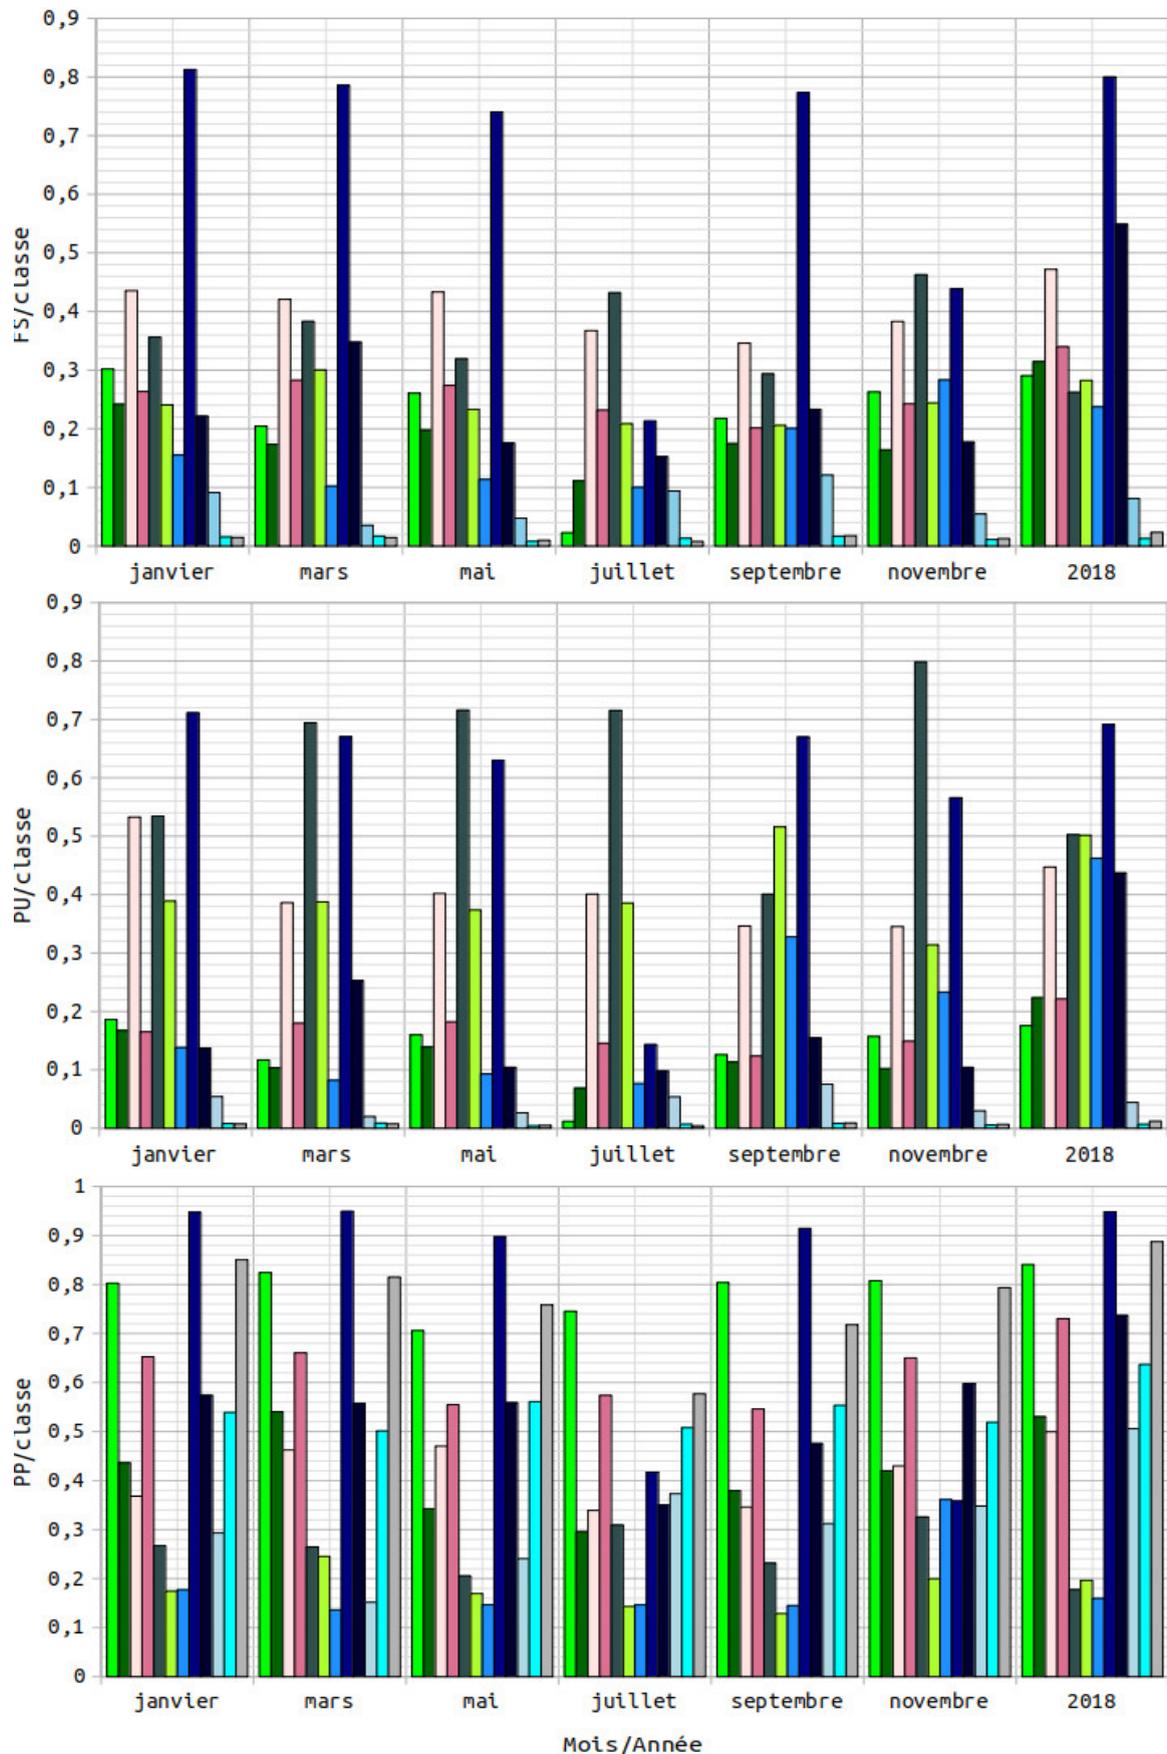


FIG. 4.37 – F-Scores et précision utilisateur et précision producteur par classe des classifications supervisées de séries temporelles d’images optiques Sentinel-2_L2A avec le Modèle4 et la légende à 12 classes : ■ : VNC; ■ : VHB; ■ : FOU; ■ : FFE; ■ : TCU; ■ : ARB; ■ : ZHH; ■ : SFE; ■ : ZHU; ■ : RIV; ■ : RTE; ■ : BTM de la zone d’étude ZONE1.

pour la classification d'images optiques Sentinel-2 seules pour la légende à 5 classes. La confusion s'atténue avec l'utilisation des classes FRT et ARB, et les taux de *FP* baissent de 14,5% à 5% pour la classe FRT et de 17,3% à 15,6% pour la classe ARB. Par contre, la confusion s'accroît avec l'utilisation de la classe PRA, et le taux de *FP* augmente de 13% à 19,2%. Concernant la confusion avec la classe EAU, elle s'atténue et les taux de *FP* baissent pour les légendes à 5 et 9 classes en affectant principalement l'optique. De plus, cette confusion s'atténue davantage avec l'ajout de nouvelles classes pour la légende à 12 classes. C'est ainsi que **la confusion entre les classes VNC et RIV s'atténue fortement avec un taux de *FP* qui baisse de 38,3% à 14,2%. Cette diminution de *FP* se fait au détriment des *FN*, avec une forte augmentation de ceux-ci lors de la classification sur l'ensemble de la zone d'étude ZONE1.**

Par ailleurs, pour 5 classes sur l'ensemble de la ZONE1, la classe RTE est classifiée en AGR avec un taux de *FP*=10,3%. À l'inverse, la classe AGR est classifiée en RTE avec un taux supérieur de *FN*=36,5%. Ce taux baisse et devient *FN*=27% contrairement au taux de *FP* qui reste inchangé et la confusion demeure pour la légende à 9 classes. De plus, pour cette légende, les classes SFE et RIV sont classifiées en RTE et ARB avec des taux de *FP*=0,1% et *FP*=4,6% respectivement. Inversement, les classes RTE et ARB sont classifiées en SFE et RIV avec des taux très inférieurs de *FN*=0% et *FN*=0,6%. Ces taux restent constants ou augmentent et deviennent *FN*=0% et *FN*=2% de même que les taux de *FP* qui deviennent respectivement *FP*=0,1% et *FP*=1,3% et les confusions s'atténuent très peu pour la légende à 12 classes. En outre, pour la légende à 9 classes, la classe RTE est classifiée en RIV avec un petit taux de *FP*=1%. À l'inverse, la classe RIV est classifiée en RTE avec un taux supérieur de *FN*=7,8%. Ce taux baisse à *FN*=5% contrairement au taux de *FP* qui est multiplié par 2 et devient *FP*=2,7% et la confusion s'accroît dans ce cas pour la légende à 12 classes. En général, **les taux de *FN* baissent et la discrimination des classes devient difficile à quelques exceptions près telles que les paires de classes (SFE et RTE) et (RIV et ARB) dont les confusions s'atténuent légèrement en utilisant les images Sentinel-2_L2A seules avec l'ajout de nouvelles classes pour la légende à 12 classes.**

TAB. 4.13 – Matrice de confusion avec la légende à 5 classes.

L2A_M4		Vérité Terrain					PU
% VU	CL	VGT	AGR	EAU	RTE	BTM	
11,8	VGT	47,1	10,4	5,2	4,3	0,2	73,7
77,1	AGR	25,0	44,3	22,7	10,3	1,9	72,5
2,2	EAU	5,1	6,9	58,8	1,9	0,1	18,0
0,1	RTE	22,5	36,5	11,9	70,0	9,6	0,4
0,1	BTM	0,2	2,0	1,3	13,6	88,3	1,4
	PP	47,1	44,3	58,8	70,0	88,3	

TAB. 4.14 – Matrice de confusion avec la légende à 9 classes.

L2A_M4		Vérité Terrain									PU
% VU	CL	FRT	PRA	ARB	AGR	SFE	ZHU	RIV	RTE	BTM	
0,8	FRT	55,0	9,5	8,6	4,0	0,4	4,8	3,3	1,2	0,1	2,5
7,4	PRA	20,0	46,8	17,5	4,8	0,0	4,9	2,1	3,0	0,0	81,8
4,1	ARB	9,6	6,9	37,9	6,1	0,1	1,1	4,6	3,3	0,3	7,4
77,1	AGR	5,0	19,2	15,6	43,4	0,3	8,0	4,7	10,3	2,2	80,5
4,2	SFE	0,4	0,0	0,0	0,1	95,3	3,1	2,2	0,0	0,0	94,4
0,9	ZHU	5,2	1,9	14,8	10,9	2,8	71,8	3,7	3,9	0,5	13,4
0,2	RIV	1,7	2,1	0,6	1,7	1,1	3,6	70,4	1,0	0,2	6,8
0,1	RTE	2,4	13,5	4,4	27,0	0,1	2,3	7,8	64,3	9,0	0,6
0,1	BTM	0,6	0,1	0,7	1,8	0,0	0,5	1,3	13,0	87,7	1,6
	PP	55,0	46,8	37,9	43,4	95,3	71,8	70,4	64,3	87,7	

TAB. 4.15 – Matrice de confusion avec la légende à 12 classes.

L2A_M4		Vérité Terrain												PU
% VU	CL	VNC	VHB	FOU	FFE	TCU	ARB	ZHH	SFE	ZHU	RIV	RTE	BTM	
0,1	VNC	84,0	1,8	0,0	0,0	0,0	0,1	10,8	0,3	2,3	28,7	0,0	0,0	17,5
0,6	VHB	0,2	53,0	4,3	0,6	6,4	12,7	7,4	0,5	4,1	1,9	2,5	0,3	22,3
4,5	FOU	0,0	8,0	50,0	22,0	5,3	19,6	1,4	0,2	3,3	1,9	3,9	0,1	44,7
0,5	FFE	0,0	1,4	29,5	73,0	0,5	4,8	0,7	0,0	2,2	0,9	0,8	0,0	22,1
45,0	TCU	0,1	9,7	1,7	0,3	48,7	18,0	0,3	0,1	3,0	1,4	7,3	1,4	50,3
18,2	ARB	0,0	10,4	9,3	2,4	10,2	29,2	0,2	0,0	2,2	1,3	5,7	0,4	50,2
11,5	ZHH	0,9	1,6	0,1	0,0	0,2	0,2	48,2	1,2	1,2	1,1	0,1	0,0	46,2
4,2	SFE	0,2	0,4	0,1	0,3	0,0	0,0	16,0	94,8	0,8	1,5	0,0	0,0	69,1
0,9	ZHU	0,3	2,3	1,6	1,0	2,0	2,3	4,4	1,0	73,7	5,2	1,6	0,3	43,7
0,2	RIV	14,2	3,3	1,3	0,3	5,7	2,0	9,5	1,9	5,2	50,6	2,7	0,4	4,4
0,1	RTE	0,0	6,3	2,0	0,1	17,7	9,8	0,7	0,1	1,7	5,0	63,7	8,2	0,7
0,1	BTM	0,0	1,9	0,3	0,0	3,2	1,1	0,4	0,0	0,3	0,5	11,6	88,7	1,2
	PP	84,0	53,0	50,0	73,0	48,7	29,2	48,2	94,8	73,7	50,6	63,7	88,7	

% VU : pourcentage de données vecteurs utilisées.

CL : classification. M4 : Modèle4.

4.6.2 Artefacts dans les classifications

L'objectif de cette partie est d'analyser la qualité de la classification en utilisant chacun des quatre modèles - Modèle1, Modèle2, Modèle3 et Modèle4 - sur la zone d'étude ZONE1. Comme décrit en Section 3.2.3.1.1, les images utilisées n'offrent pas une couverture homogène : couverture nuageuse et ombres des nuages, limites de fauchée des satellites, absence de certaines acquisitions. L'étape de pré-traitement peut également écarter certaines images en raison de critères de qualité, pour les images acquises avec une couverture nuageuse très élevée (supérieure à 90%) qui ne permettent pas l'extraction de points homologues pour l'ortho-rectification ou encore l'estimation de l'épaisseur optique atmosphérique nécessaire pour l'estimation de la réflectance de surface. Cela peut aussi entraîner l'élimination des scènes complètes (dans l'étape d'ortho-rectification) ou des tuiles Sentinel-2 (dans l'étape de correction atmosphérique) qui impacte ainsi la qualité du remplissage et du ré-échantillonnage temporels en rendant très différents, des pixels adjacents qui devraient en réalité être presque identiques.

Une autre source d'imperfections provient du fait que plusieurs modèles de classification sont entraînés sur différentes tailles de zone d'apprentissage. **Chaque modèle d'étude est utilisé indépendamment pour classifier la zone d'étude ZONE1. La classification de cette zone avec ces différents modèles d'étude peut donc introduire des discontinuités aux limites des tuiles.** Ces erreurs sont rares et n'ont donc pas de poids dans les mesures statistiques de qualité, mais peuvent être gênantes visuellement ou significatives localement. Les Figures 4.38, 4.39, 4.40 et 4.41 illustrent quelques artefacts avec les Modèle1, Modèle2, Modèle3 et Modèle4 sur la zone d'étude ZONE1. Ils se trouvent bien sur les limites des tuiles Sentinel-2. On peut aisément remarquer que **certaines artefacts disparaissent au fur et à mesure que la taille de la zone d'entraînement augmente (surtout dans sa partie Ouest) avec les Modèle1 jusqu'au Modèle3** dans lesquelles des imperfections subsistent vraisemblablement du fait de l'étape de pré-traitement précédemment décrite avant s'amenuisent presque complètement dans la classification avec le Modèle4 (Figure 4.41).

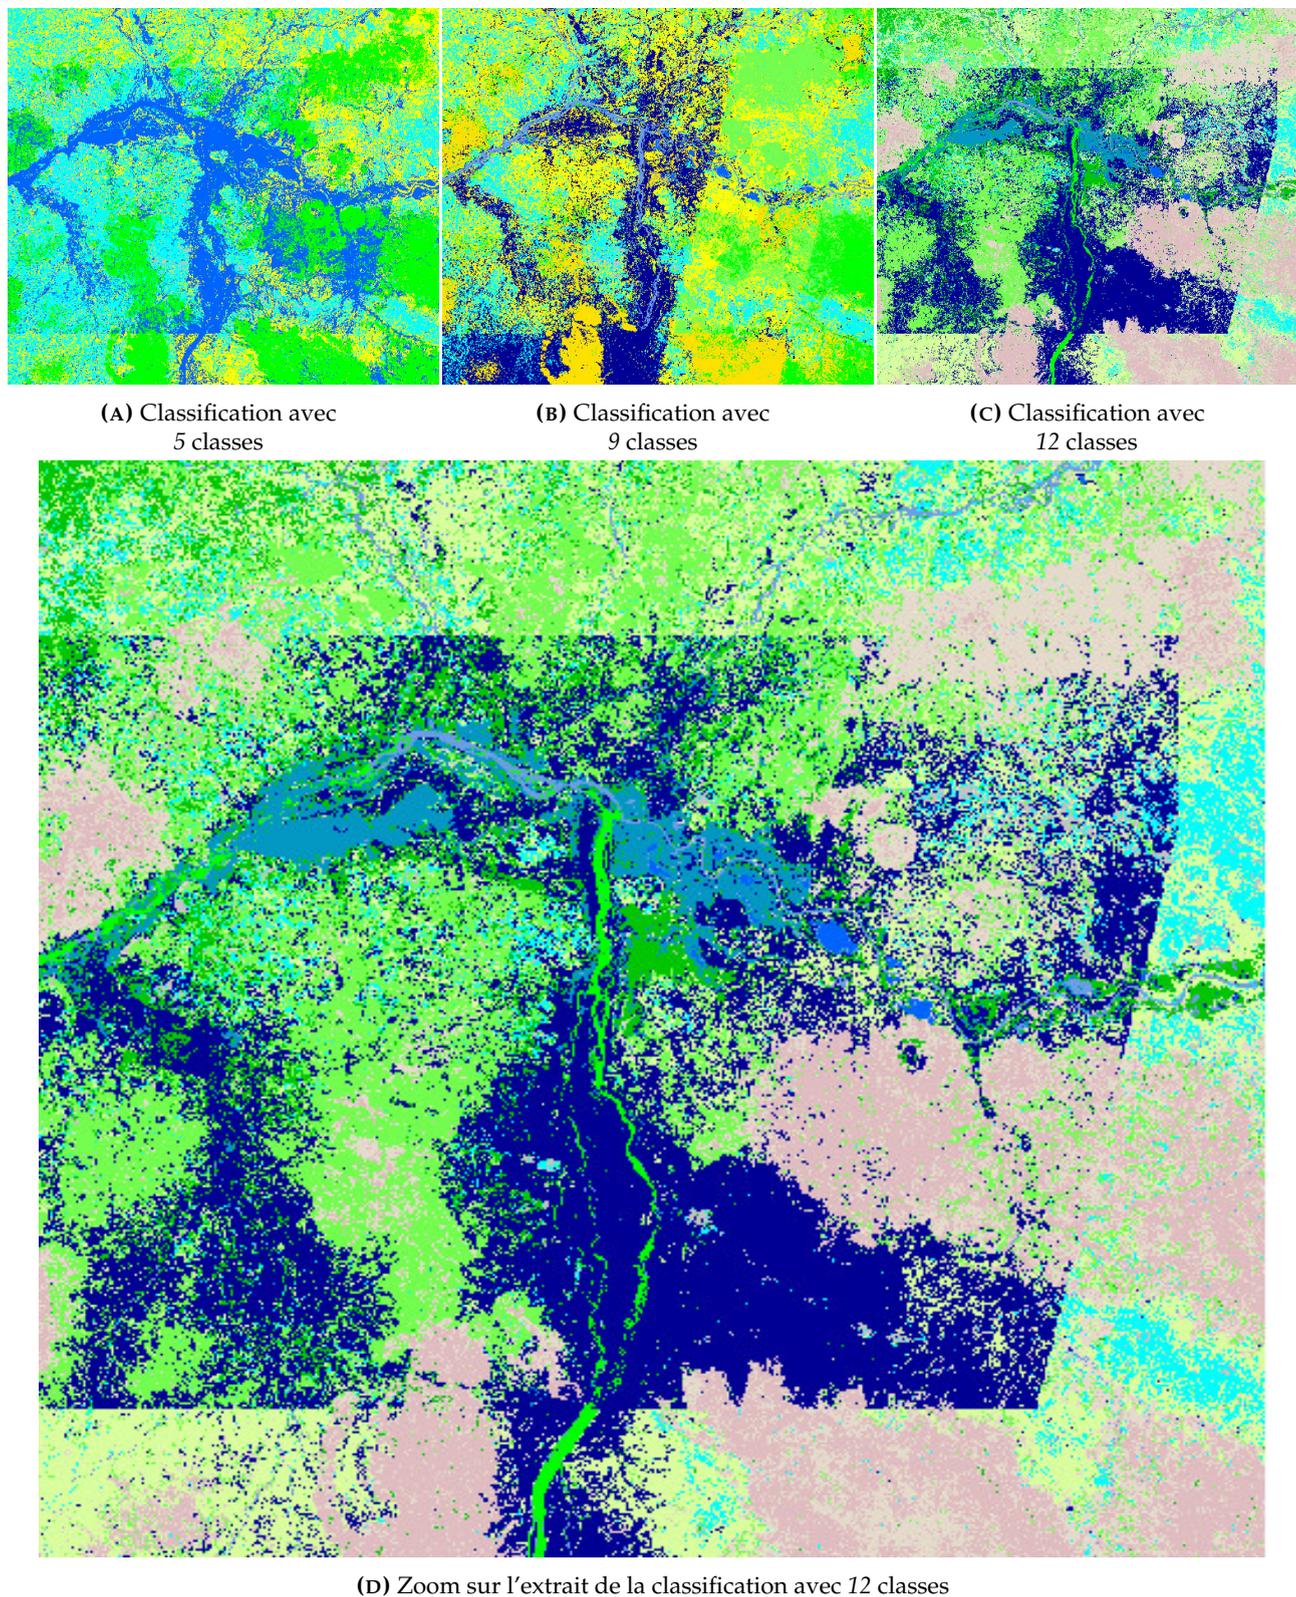


FIG. 4.38 – Extraits des classifications de séries temporelles d'images optiques Sentinel-2_L2A avec le Modèle1 et les légendes à 5 : ■ : VGT; ■ : AGR; ■ : EAU; ■ : RTE; ■ : BTM et 9 : ■ : FRT; ■ : PRA; ■ : ARB; ■ : AGR; ■ : SFE; ■ : ZHU; ■ : RIV; ■ : RTE; ■ : BTM et 12 : ■ : VNC; ■ : VHB; ■ : FOU; ■ : FFE; ■ : TCU; ■ : ARB; ■ : ZHH; ■ : SFE; ■ : ZHU; ■ : RIV; ■ : RTE; ■ : BTM classes de la zone d'étude ZONE1.

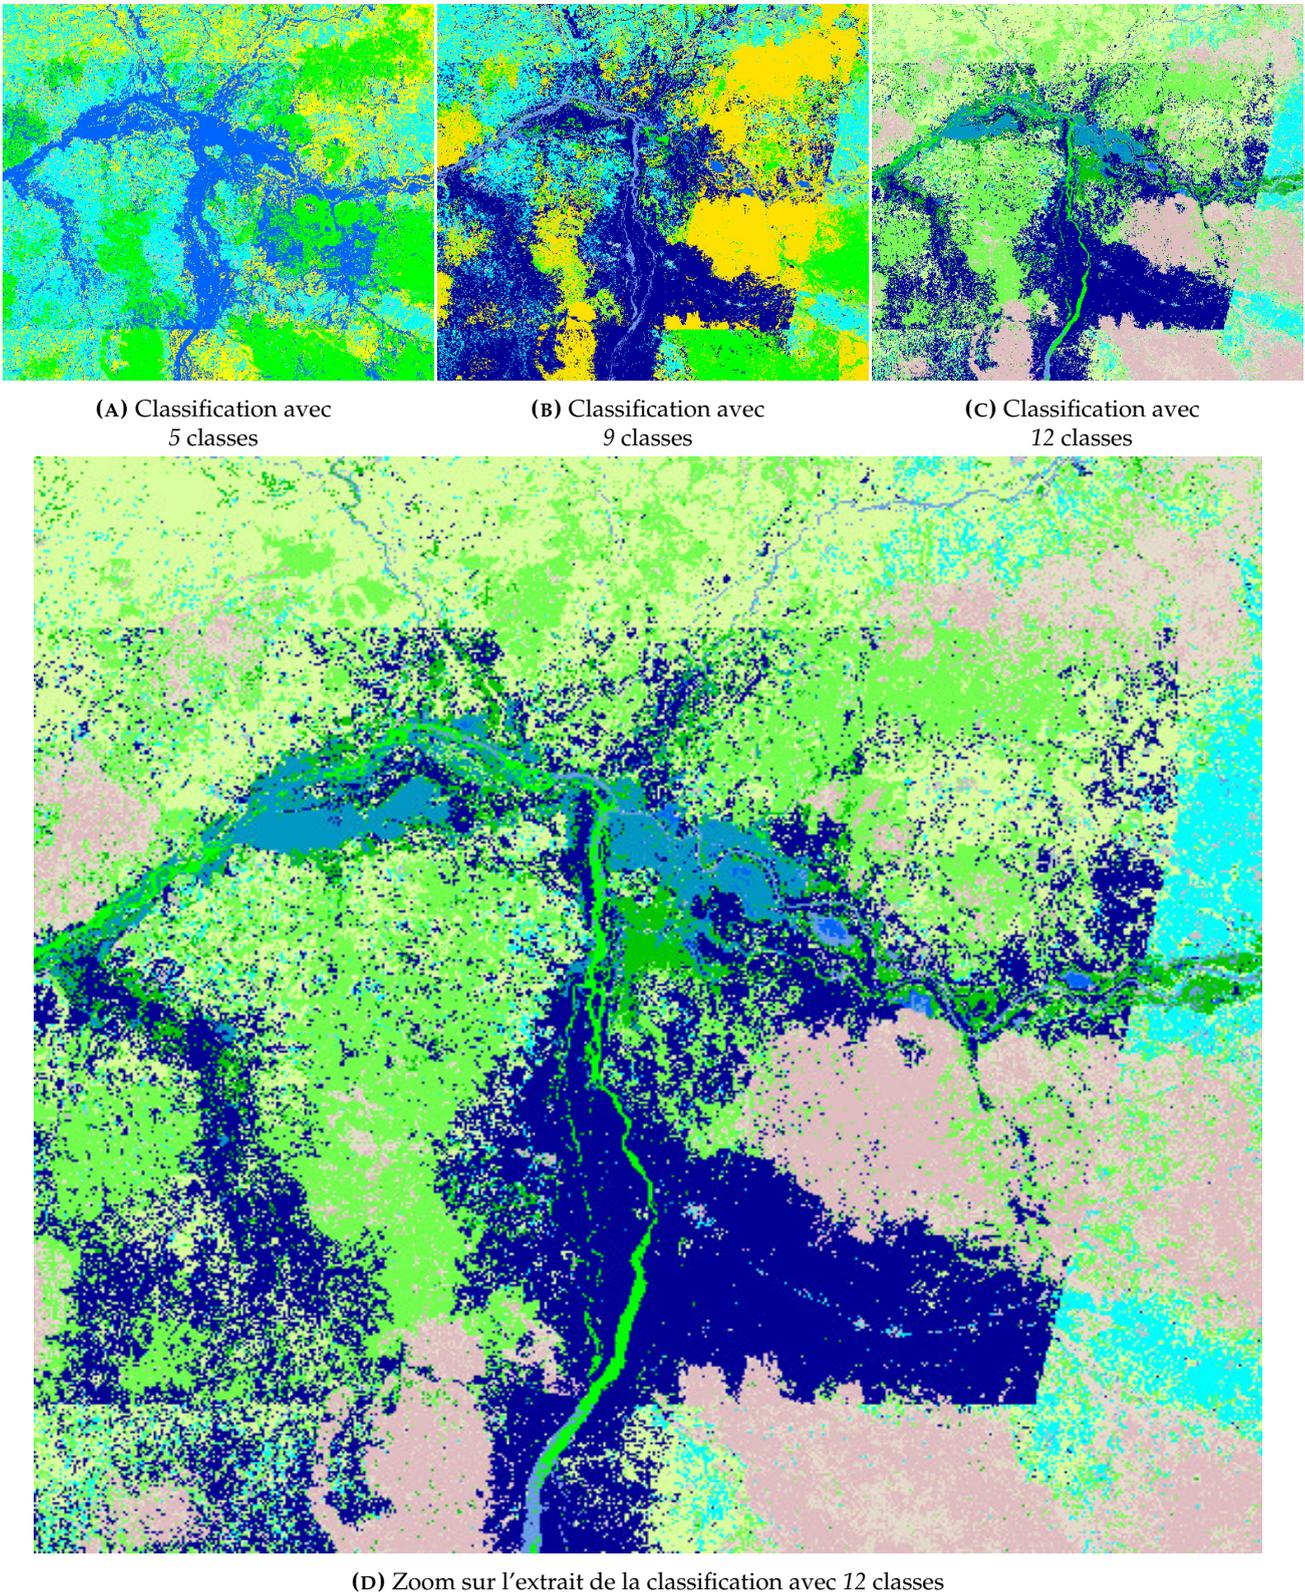


FIG. 4.39 – Extraits des classifications de séries temporelles d'images optiques Sentinel-2_L2A avec le Modèle2 et les légendes à 5 : ■ : VGT; ■ : AGR; ■ : EAU; ■ : RTE; ■ : BTM et 9 : ■ : FRT; ■ : PRA; ■ : ARB; ■ : AGR; ■ : SFE; ■ : ZHU; ■ : RIV; ■ : RTE; ■ : BTM et 12 : ■ : VNC; ■ : VHB; ■ : FOU; ■ : FFE; ■ : TCU; ■ : ARB; ■ : ZHH; ■ : SFE; ■ : ZHU; ■ : RIV; ■ : RTE; ■ : BTM classes de la zone d'étude ZONE1.

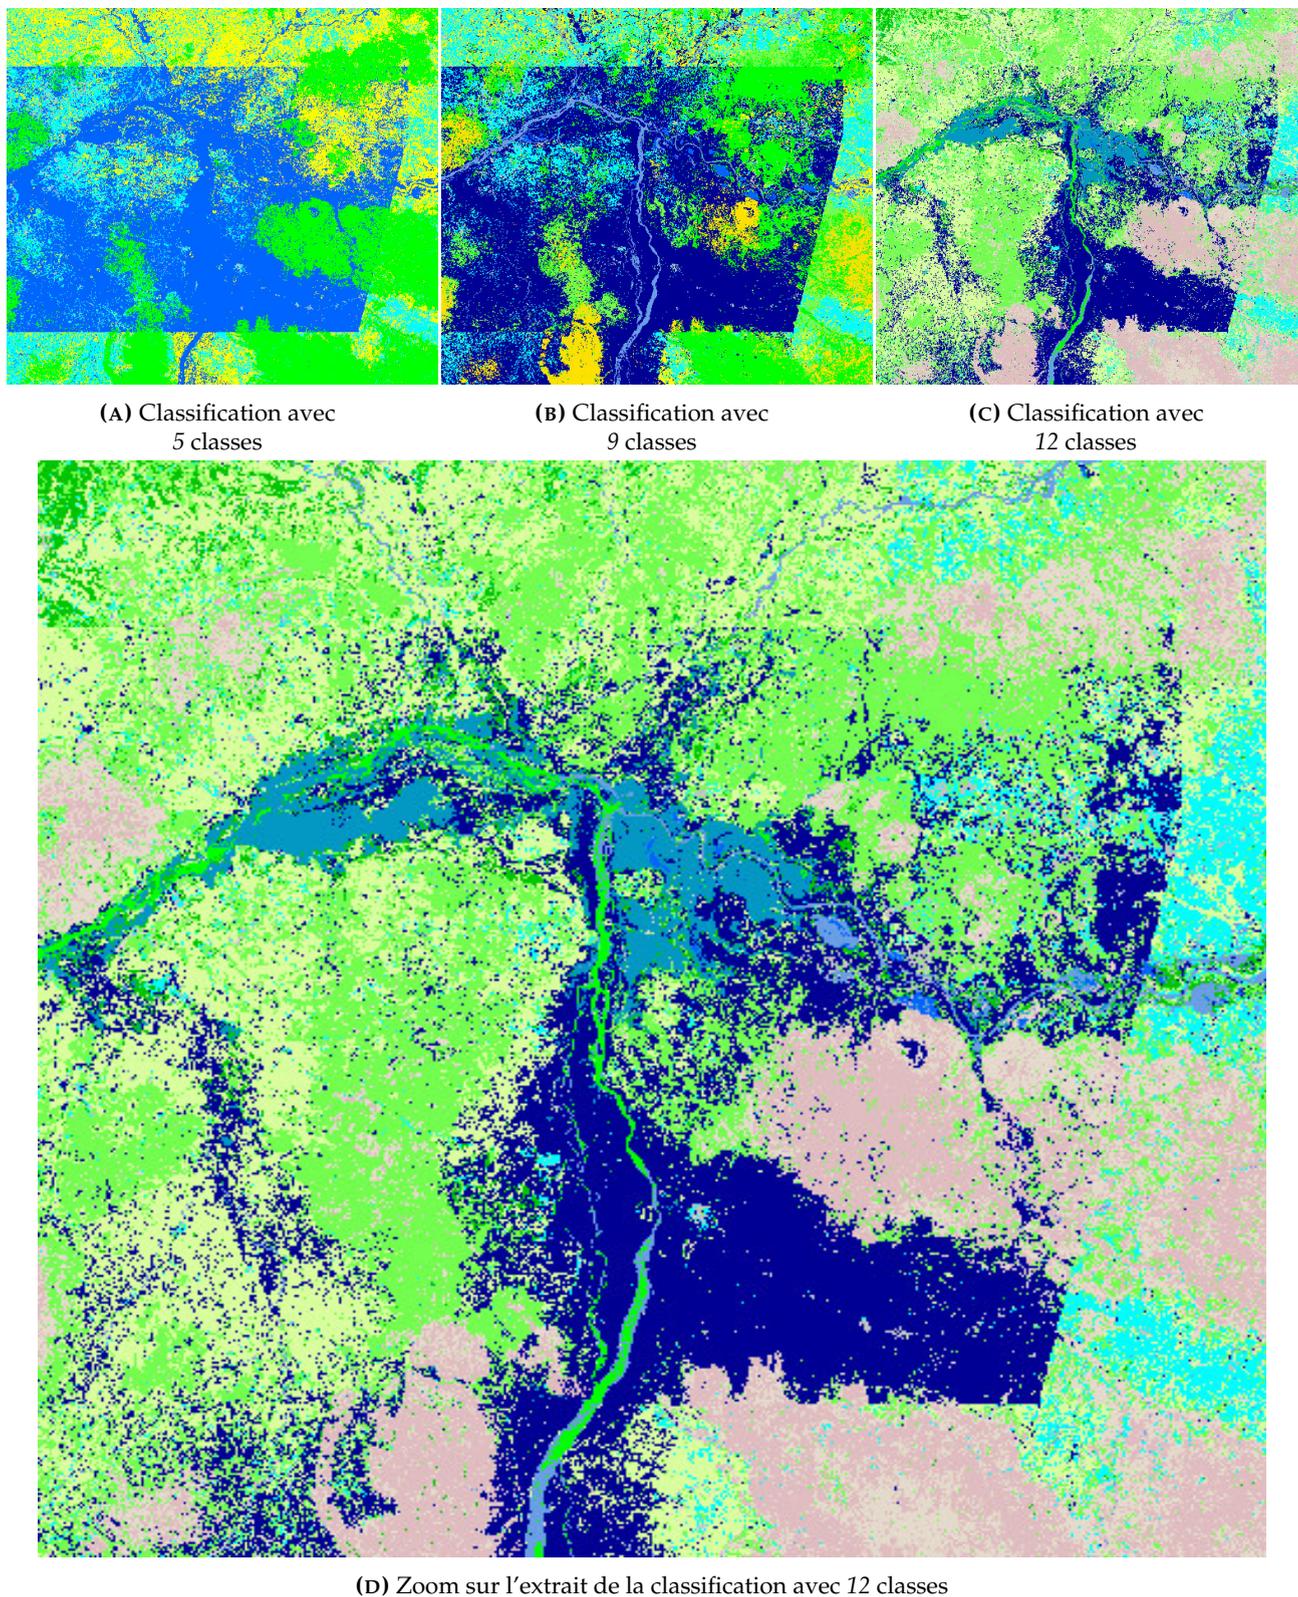


FIG. 4.40 – Extraits des classifications de séries temporelles d'images optiques Sentinel-2_L2A avec le Modèle3 et les légendes à 5 : ■ : VGT; ■ : AGR; ■ : EAU; ■ : RTE; ■ : BTM et 9 : ■ : FRT; ■ : PRA; ■ : ARB; ■ : AGR; ■ : SFE; ■ : ZHU; ■ : RIV; ■ : RTE; ■ : BTM et 12 : ■ : VNC; ■ : VHB; ■ : FOU; ■ : FFE; ■ : TCU; ■ : ARB; ■ : ZHH; ■ : SFE; ■ : ZHU; ■ : RIV; ■ : RTE; ■ : BTM classes de la zone d'étude *ZONE1*.

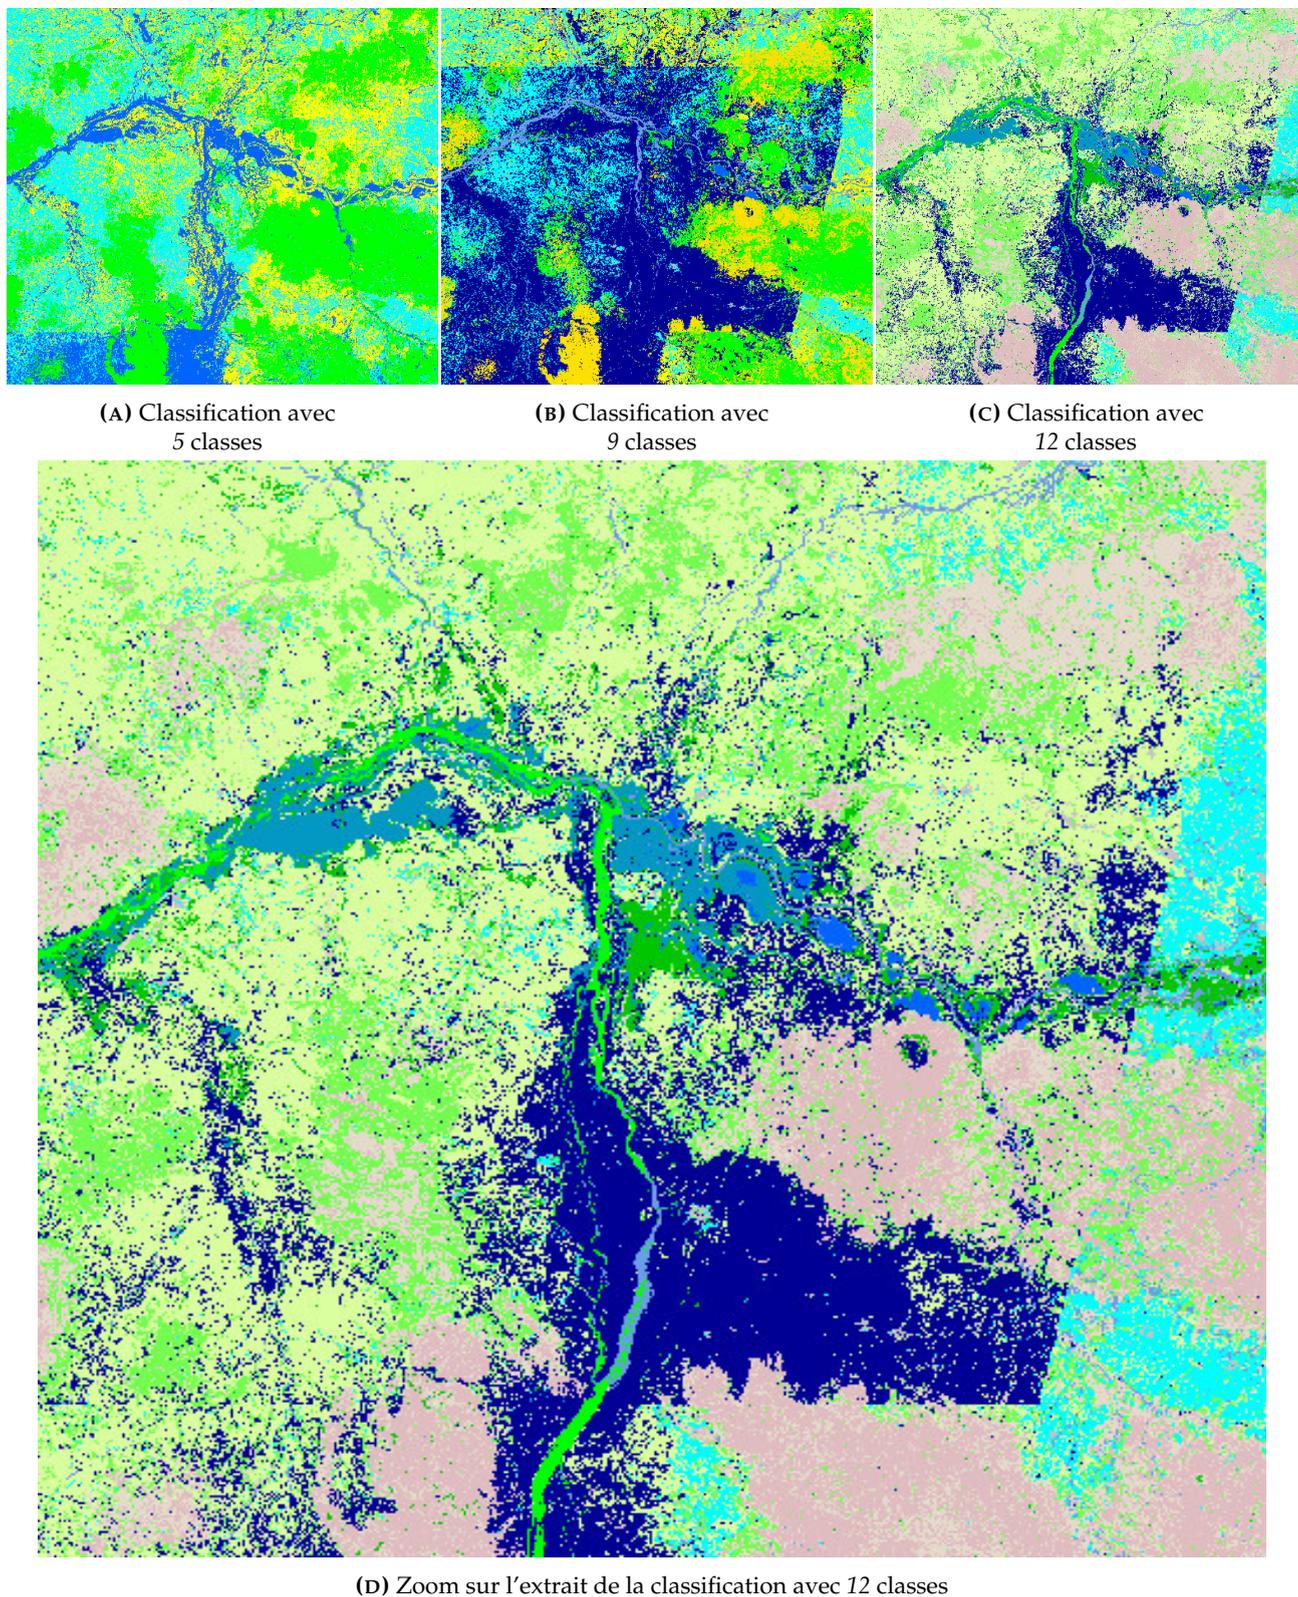


FIG. 4.41 – Extraits des classifications de séries temporelles d'images optiques Sentinel-2_L2A avec le Modèle4 et les légendes à 5 : ■ : VGT; ■ : AGR; ■ : EAU; ■ : RTE; ■ : BTM et 9 : ■ : FRT; ■ : PRA; ■ : ARB; ■ : AGR; ■ : SFE; ■ : ZHU; ■ : RIV; ■ : RTE; ■ : BTM et 12 : ■ : VNC; ■ : VHB; ■ : FOU; ■ : FFE; ■ : TCU; ■ : ARB; ■ : ZHH; ■ : SFE; ■ : ZHU; ■ : RIV; ■ : RTE; ■ : BTM classes de la zone d'étude ZONE1.

4.6.3 Comparaison pixel à pixel des classifications

L'objectif de cette section est d'effectuer la comparaison pixel à pixel entre les classifications supervisées des différents mois et de l'année complète 2018 avec les quatre modèles d'étude - Modèle1, Modèle2, Modèle3 et Modèle4 - par entraînement du classifieur sur trois, quatre, cinq ou toutes les six tuiles Sentinel-2, de la zone d'étude ZONE1.

4.6.3.1 Modèle1

Le Tableau 4.16 présente les différentes valeurs de K et FS pour les douze mois et de l'année complète 2018 pour le cas 9 classes. On observe que toutes les classifications mensuelles et annuelle ne s'accordent pas avec la VT. De plus, on peut constater de faibles scores de similarité K et FS entre les classifications des mois de juillet et septembre et les autres classifications et la VT, traduisant ici le fait que ces classifications sont différentes. **Les valeurs de K et de FS sont plus élevées dans chacune des classifications des mois de janvier, mars, novembre et de l'année complète par rapport aux autres classifications mensuelles et annuelle et la VT qui possèdent ainsi les meilleurs taux d'accord.** Au contraire, la classification du mois de septembre possède le plus faible taux d'accord par rapport au reste des classifications et la VT.

TAB. 4.16 – Coefficients Kappa (K) et F-Scores moyens (FS) après comparaison pixel à pixel des classifications du Modèle1 et la VT avec la légende à 9 classes.

	jan.		mar.		mai		juil.		sep.		nov.		2018		VT	
<i>k = 9</i>																
L2A	K	FS	K	FS	K	FS	K	FS	K	FS	K	FS	K	FS	K	FS
janvier	1,0	100,0	0,4	50,3	0,3	38,7	0,3	35,5	0,2	36,1	0,3	44,6	0,3	44,2	0,1	3,8
mars	0,4	50,3	1,0	100,0	0,3	38,1	0,3	33,4	0,2	32,9	0,3	40,3	0,3	42,7	0,1	4,3
mai	0,3	38,7	0,3	38,1	1,0	100,0	0,3	33,5	0,2	32,3	0,2	36,3	0,3	38,7	0,1	7,9
juillet	0,3	35,5	0,3	33,4	0,3	33,5	1,0	100,0	0,2	31,5	0,3	34,5	0,3	35,2	0,1	4,8
septembre	0,2	36,1	0,2	32,9	0,2	32,3	0,2	31,5	1,0	100,0	0,2	36,8	0,2	39,4	0,1	5,4
novembre	0,3	44,6	0,3	40,3	0,2	36,3	0,3	34,5	0,2	36,8	1,0	100,0	0,3	44,6	0,1	3,8
2018	0,3	44,2	0,3	42,7	0,3	38,7	0,3	35,2	0,2	39,4	0,3	44,6	1,0	100,0	0,1	7,2
VT	0,1	3,8	0,1	4,3	0,1	7,9	0,1	4,8	0,1	5,4	0,1	3,8	0,1	7,2	1,0	100,0

k : nombre de classes. *VT* : vérité terrain.

4.6.3.2 Modèle2

Les résultats sont fournis dans le Tableau 4.17 selon une configuration identique. Là, on remarque de faibles scores de similarité K et FS issus des comparaisons entre les classifications des mois de mai et juillet et les autres classifications et la VT. Les valeurs de K et de FS sont plus élevées dans chacune des classifications des mois de janvier, mars, novembre et de l'année complète alors que le mois de mai possède le plus faible taux d'accord.

TAB. 4.17 – Coefficients Kappa (K) et F-Scores moyens (FS) après comparaison pixel à pixel des classifications du Modèle2 et la VT avec la légende à 9 classes.

	jan.		mar.		mai		juil.		sep.		nov.		2018		VT	
<i>k = 9</i>																
L2A	K	FS	K	FS	K	FS	K	FS	K	FS	K	FS	K	FS	K	FS
janvier	1,0	100,0	0,3	41,8	0,2	31,6	0,2	31,0	0,2	33,6	0,4	44,9	0,4	43,0	0,1	3,6
mars	0,3	41,8	1,0	100,0	0,2	30,4	0,2	27,5	0,1	27,1	0,2	35,6	0,3	40,8	0,1	3,1
mai	0,2	31,6	0,2	30,4	1,0	100,0	0,2	28,5	0,2	29,1	0,2	34,3	0,2	32,8	0,1	8,0
juillet	0,2	31,0	0,2	27,5	0,2	28,5	1,0	100,0	0,2	30,3	0,3	34,2	0,3	35,0	0,1	4,9
septembre	0,2	33,6	0,1	27,1	0,2	29,1	0,2	30,3	1,0	100,0	0,3	40,0	0,2	38,0	0,1	5,3
novembre	0,4	45,0	0,2	35,6	0,2	34,3	0,2	34,2	0,3	40,0	1,0	100,0	0,3	45,1	0,1	4,3
2018	0,4	43,0	0,3	40,8	0,2	32,8	0,3	35,0	0,2	38,0	0,3	45,1	1,0	100,0	0,1	5,0
VT	0,1	3,6	0,1	3,1	0,1	8,0	0,1	4,9	0,1	5,3	0,1	4,3	0,1	5,0	1,0	100,0

k : nombre de classes. VT : vérité terrain.

4.6.3.3 Modèle3

Dans le Tableau 4.18, de nouveau, toutes les classifications mensuelles et annuelle ne s'accordent pas avec la VT. De plus, on peut remarquer de faibles scores de similarité K et FS pour les mois de mars et septembre. Les valeurs de K et de FS sont plus élevées dans chacune des classifications des mois de janvier, mai, novembre et de l'année complète et comme pour le Modèle1, le mois de septembre possède le plus faible taux d'accord.

TAB. 4.18 – Coefficients Kappa (K) et F-Scores moyens (FS) après comparaison pixel à pixel des classifications du Modèle3 et la VT avec la légende à 9 classes.

	jan.		mar.		mai		juil.		sep.		nov.		2018		VT	
<i>k = 9</i>																
L2A	K	FS	K	FS	K	FS	K	FS	K	FS	K	FS	K	FS	K	FS
janvier	1,0	100,0	0,3	45,3	0,3	37,8	0,3	35,7	0,2	34,3	0,4	45,8	0,4	49,7	0,1	3,8
mars	0,3	45,4	1,0	100,0	0,2	33,3	0,2	29,6	0,2	28,2	0,3	36,5	0,3	41,3	0,1	4,1
mai	0,3	37,8	0,2	33,3	1,0	100,0	0,3	33,1	0,2	30,6	0,3	37,3	0,4	41,0	0,1	8,0
juillet	0,3	35,7	0,2	29,6	0,3	33,1	1,0	100,0	0,2	30,5	0,3	36,2	0,4	39,8	0,1	4,2
septembre	0,2	34,3	0,2	28,2	0,2	30,6	0,2	30,5	1,0	100,0	0,3	37,4	0,3	40,7	0,2	5,0
novembre	0,4	45,8	0,3	36,5	0,3	37,3	0,3	36,2	0,3	37,4	1,0	100,0	0,4	50,2	0,1	3,8
2018	0,4	49,7	0,3	41,3	0,4	41,0	0,4	39,8	0,3	40,7	0,4	50,2	1,0	100,0	0,1	5,9
VT	0,1	3,8	0,1	4,1	0,1	8,0	0,1	4,2	0,2	5,0	0,1	3,8	0,1	5,9	1,0	100,0

k : nombre de classes. VT : vérité terrain.

4.6.3.4 Modèle4

Le Tableau 4.19 désigne les mois de juillet et septembre comme ayant un faible taux d'accord, septembre étant le minimum. Janvier, mai, novembre et l'année complète montrent les meilleurs taux d'accord.

TAB. 4.19 – Coefficients Kappa (K) et F-Scores moyens (FS) après comparaison pixel à pixel des classifications du Modèle4 et la VT avec la légende à 9 classes.

	jan.		mar.		mai		juil.		sep.		nov.		2018		VT	
<i>k = 9</i>																
<i>L2A</i>	K	FS	K	FS	K	FS	K	FS	K	FS	K	FS	K	FS	K	FS
janvier	1,0	100,0	0,4	50,4	0,7	72,2	0,3	35,1	0,2	33,0	0,4	45,8	0,3	44,9	0,1	3,8
mars	0,4	50,4	1,0	100,0	0,4	48,0	0,3	33,7	0,2	32,0	0,3	41,7	0,3	43,3	0,1	3,0
mai	0,7	72,2	0,4	48,0	1,0	100,0	0,2	32,9	0,2	33,9	0,3	44,5	0,3	45,8	0,1	3,2
juillet	0,3	35,1	0,3	33,7	0,2	32,9	1,0	100,0	0,2	29,7	0,3	36,2	0,3	36,0	0,1	4,8
septembre	0,2	33,0	0,2	31,6	0,2	33,9	0,2	29,7	1,0	100,0	0,2	36,3	0,3	40,6	0,1	6,3
novembre	0,4	45,8	0,3	41,7	0,3	44,5	0,3	36,2	0,2	36,3	1,0	100,0	0,4	46,3	0,1	3,4
2018	0,3	44,9	0,3	43,3	0,3	45,8	0,3	36,0	0,3	40,6	0,4	46,3	1,0	100,0	0,1	6,9
VT	0,1	3,8	0,1	3,0	0,1	3,2	0,1	4,8	0,1	6,3	0,1	3,4	0,1	6,9	1,0	100,0

k : nombre de classes. VT : vérité terrain.

4.6.4 Comparaison par région des distributions de classes des classifications

L'objectif est désormais de comparer la moyenne des scores calculés au sein de grandes régions extraites des classifications des différents mois et de l'année complète 2018 avec les quatre modèles d'étude, toujours sur la zone d'étude ZONE1.

4.6.4.1 Modèle1

Le Tableau 4.20 présente les moyennes des scores calculés au sein de cellules de taille 200 pixels extraites des classifications supervisées de séries temporelles d'images optiques Sentinel-2_L2A des douze mois et de l'année complète 2018 avec le Modèle1 et de la VT utilisant la légende à 9 classes. On constate que **toutes les classifications sont très différentes de la VT avec des scores les plus élevées de 0,57 à 1,05**. Plus précisément, on peut également remarquer que **les classifications du mois de mai et de l'année complète sont les plus proches de la VT avec des valeurs respectives moins fortes de 0,57 et 0,76**. Par ailleurs, **les classifications du mois de mai et de l'année complète se rapprochent en étant toutes les deux les plus éloignées des autres classifications avec de fortes valeurs des scores de 0,44 à 0,47**, ce qui explique les bonnes qualités de séries d'images Sentinel-2 qui comportent très peu de nuages du fait de la saison sèche qui sévit pendant le mois de mai sur la zone Nord. De même, les deux groupes de classifications mensuelles et annuelle (janvier, septembre et 2018) et (janvier, mars et novembre) sont très peu proches de celles du mois de mai et de l'année complète avec des scores faibles de 0,45 et 0,44 respectivement. De plus, les deux paires de classifications mensuelles et annuelle (septembre et 2018) et (mars et juillet) ne se rapprochent également pas de celles de l'année complète et du mois de novembre avec de faibles scores de 0,44 et 0,39 respectivement.

L2A	jan.	mar.	mai	juil.	sep.	nov.	2018	VT
janvier	0.00	0.31	0.45	0.37	0.40	0.33	0.44	1.05
mars	0.31	0.00	0.47	0.41	0.44	0.39	0.44	0.96
mai	0.45	0.47	0.00	0.46	0.45	0.47	0.45	0.57
juillet	0.37	0.41	0.46	0.00	0.42	0.39	0.47	0.97
septembre	0.40	0.44	0.45	0.42	0.00	0.41	0.47	0.86
novembre	0.33	0.39	0.47	0.39	0.41	0.00	0.44	1.00
2018	0.44	0.44	0.45	0.47	0.47	0.44	0.00	0.76
VT	1.05	0.96	0.57	0.97	0.86	1.00	0.76	0.00

TAB. 4.20 – Moyennes des distances entre histogrammes issues des classifications du Modèle1 et de la VT avec 9 classes.

4.6.4.2 Modèle2

Avec le Tableau 4.21, on observe des valeurs au-dessus de la moyenne des scores de comparaison par région des classifications mensuelles et annuelle et la VT. On note que **toutes les classifications sont toujours très différentes de la VT avec des scores les plus élevées de 0,42 à 1,03**. Janvier et mai sont les plus proches (respectivement moins fortes de 0,42 et 0,55) et mars et juillet se rapprochent sont les plus éloignées (0,42 à 1). Ceci s'explique par les mauvaises qualités de séries d'images Sentinel-2 qui comportent des résidus de nuages du fait de la petite (en mars) et grande (en juillet) saison pluvieuse qui sévit sur la zone Nord. De même, la paire de classifications mensuelles (mars et juillet) et la VT sont très peu proches de celle du mois de janvier avec un score de 0,42. De plus, les deux paires de classifications mensuelles et annuelle (janvier et 2018) et (janvier et septembre) ne se rapprochent également pas trop de celles des mois de mars et juillet avec le même faible score de 0,42.

L2A	jan.	mar.	mai	juil.	sep.	nov.	2018	VT
janvier	0.00	0.42	0.53	0.42	0.43	0.32	0.39	1.04
mars	0.42	0.00	0.56	0.49	0.53	0.47	0.42	1.03
mai	0.53	0.56	0.00	0.51	0.48	0.49	0.54	0.55
juillet	0.42	0.49	0.51	0.00	0.45	0.42	0.43	1.00
septembre	0.43	0.53	0.48	0.45	0.00	0.38	0.50	0.84
novembre	0.32	0.47	0.49	0.42	0.38	0.00	0.41	0.99
2018	0.39	0.42	0.54	0.43	0.50	0.41	0.00	0.98
VT	1.04	1.03	0.55	1.00	0.84	0.99	0.98	0.00

TAB. 4.21 – Moyennes des distances entre histogrammes issues des classifications du Modèle2 et de la VT avec 9 classes.

4.6.4.3 Modèle3

Dans le Tableau 4.22, mai est le seul plus proche de la VT avec la valeur moins forte de 0,58, accompagné de septembre. Cela provient toujours de quelques nuages du fait de la saison pluvieuse qui sévit à partir de la fin du mois de mai sur la zone Nord. Par contre, les deux paires de classifications mensuelles (janvier et juillet) et (mars et septembre) se rapprochent des deux classifications du mois de septembre et de l'année complète avec des scores faibles de 0,42 et 0,44 respectivement.

L2A	jan.	mar.	mai	juil.	sep.	nov.	2018	VT
janvier	0.00	0.39	0.43	0.35	0.42	0.28	0.30	1.03
mars	0.39	0.00	0.51	0.48	0.49	0.43	0.44	0.97
mai	0.43	0.51	0.00	0.45	0.47	0.42	0.41	0.58
juillet	0.35	0.48	0.45	0.00	0.42	0.33	0.37	1.00
septembre	0.42	0.49	0.47	0.42	0.00	0.39	0.44	0.87
novembre	0.28	0.43	0.42	0.33	0.39	0.00	0.31	1.00
2018	0.30	0.44	0.41	0.37	0.44	0.31	0.00	0.90
VT	1.03	0.97	0.58	1.00	0.87	1.00	0.90	0.00

TAB. 4.22 – Moyennes des distances entre histogrammes issues des classifications du Modèle3 et de la VT avec 9 classes.

4.6.4.4 Modèle4

Enfin, le Tableau 4.23 met en exergue le mois de septembre et l'année complète comme les plus proches de la VT avec des valeurs respectives moins fortes de 0,81 et 0,79. Cela était tout à fait prévisible au vu de la grande taille de la zone d'entraînement sur laquelle le classifieur a été entraîné et qui a permis d'obtenir un modèle beaucoup plus fiable en prenant en compte un grand nombre d'échantillons d'apprentissage et d'outrepasser ainsi les problèmes dus aux nuages encore présents dans les séries d'images Sentinel-2 du fait de la saison pluvieuse qui sévit pendant le mois de septembre sur la zone Nord. Par contre, les quatre paires de classifications mensuelles et annuelle (mai et novembre); (septembre et 2018); (janvier et 2018) et (septembre et novembre) se rapprochent des quatre classifications des mois de mars; mai; septembre et de l'année complète avec de faibles scores de 0,35; 0,44; 0,43 et 0,43 respectivement.

<i>L2A</i>	jan.	mar.	mai	juil.	sep.	nov.	2018	VT
janvier	0.00	0.30	0.17	0.37	0.43	0.29	0.42	1.03
mars	0.30	0.00	0.35	0.43	0.47	0.35	0.44	1.04
mai	0.17	0.35	0.00	0.42	0.41	0.33	0.41	1.04
juillet	0.37	0.43	0.42	0.00	0.44	0.36	0.47	0.98
septembre	0.43	0.47	0.41	0.44	0.00	0.41	0.43	0.81
novembre	0.29	0.35	0.33	0.36	0.41	0.00	0.43	1.01
2018	0.42	0.44	0.41	0.47	0.43	0.43	0.00	0.79
VT	1.03	1.04	1.04	0.98	0.81	1.01	0.79	0.00

TAB. 4.23 – Moyennes des distances entre histogrammes issues des classifications du Modèle4 et de la VT avec 9 classes.

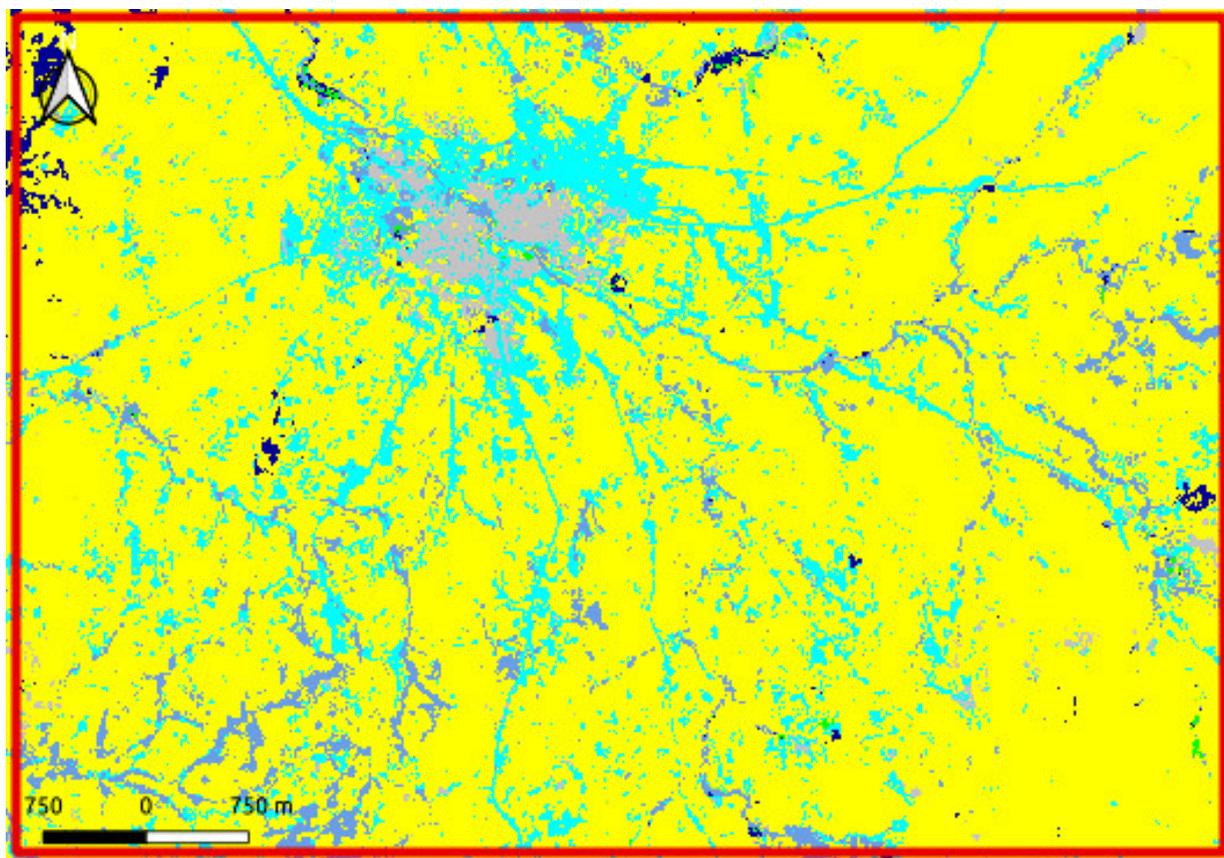
4.7 Sensibilité aux périodes de synthèse mensuelle de séries d’images Sentinel-2

L’objectif de cette section est d’évaluer l’influence des périodes de synthèse mensuelle (*JDD3*) sur les performances de classification de l’OCS. Pour ce faire, la troisième stratégie (*STR3*) (Tableau 4.2) avec le jeu de données composé uniquement de synthèses mensuelles de niveau *L3A* de séries temporelles d’images optiques Sentinel-2 est utilisé. Les cinq périodes présentées dans la Section 4.4.3.2 sont étudiées pour comparer les différentes légendes.

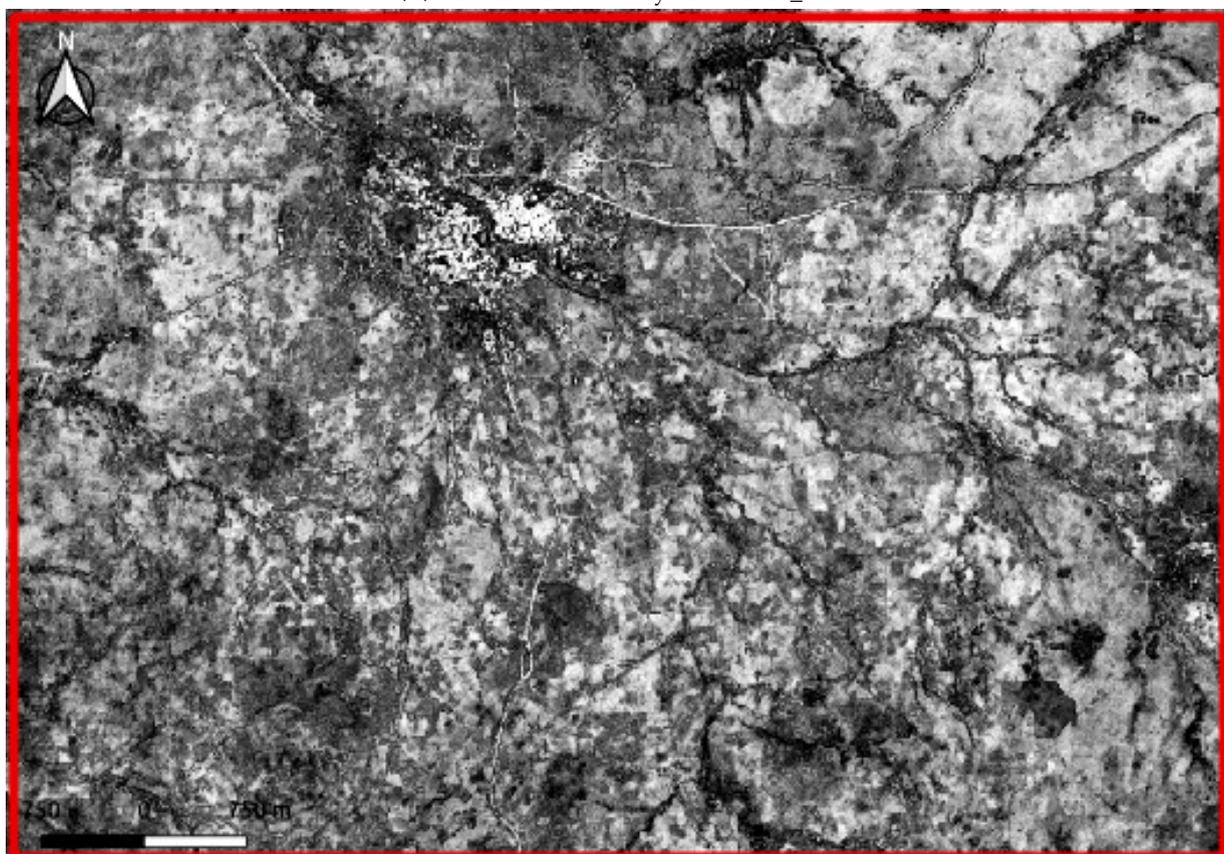
En pratique, la troisième stratégie (*STR3*) a été expérimentée pour chacune des cinq périodes de synthèse mensuelle de séries temporelles d’images Sentinel-2 (*STR3(PX)A, B*; $X \in \{45, 105, 165, 225\}$ et *STR3(P315)*) (Tableau 4.2). Dans l’optique d’une généralisation de l’ensemble des résultats obtenus, l’étude de la sensibilité des performances de classification est, ici, effectuée uniquement pour les fusions précoces (synthèses) de synthèses mensuelles *2018_P45*, *2018_P105*, *2018_P165*, *2018_P225* et *2018_P315* de périodes respectives 45, 105, 165, 225 et 315 jours. En se fondant sur les scores de performance qui sont meilleurs dans la classification de la synthèse *2018_P45*, cette étude s’est davantage focalisée sur le cas particulier des différentes synthèses de période *P45*. Dans cette section, les performances de classification supervisée de synthèses de séries temporelles d’images optiques Sentinel-2_*L3A* des deux zones d’intérêt *T33PUL* et *T32NPL* sont analysées pour chacune des trois légendes.

4.7.1 Zone d’intérêt *T33PUL* (*ZONE1*, Nord)

Les extraits des classifications supervisées des synthèses de dix, cinq et trois synthèses mensuelles de période 45 jours (*2018_P45*), 105 jours (*2018_P105*) et 165 jours (*2018_P165*) avec la légende à 9 classes de la zone *T33PUL* sont respectivement présentées dans les Figures 4.42A, 4.43A et 4.44A.

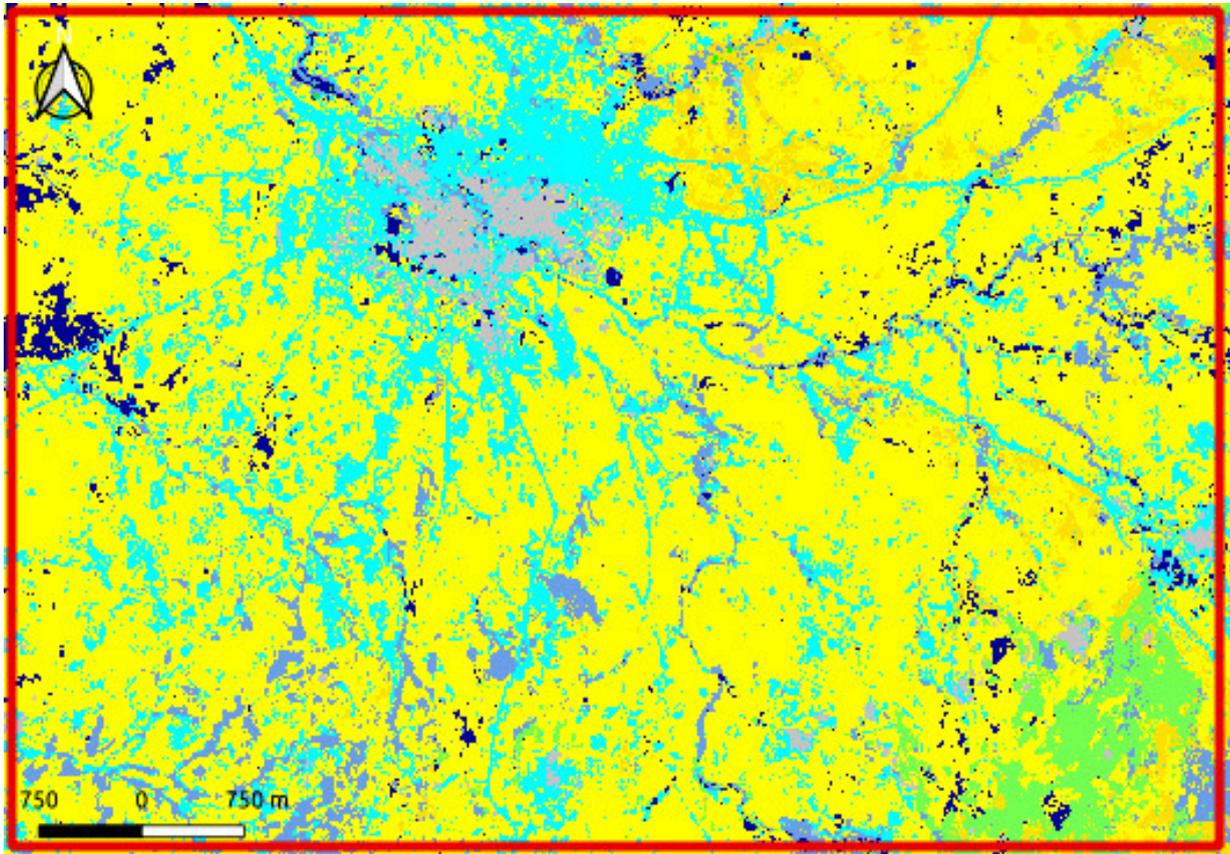


(A) Classification de la synthèse 2018_P45



(B) Confiance de la classification de la synthèse 2018_P45

FIG. 4.42 – Extraits de la classification supervisée de la synthèse 2018_P45 de séries temporelles d'images optiques Sentinel-2_L3A avec la légende à 9 classes : ■ : FRT ; ■ : PRA ; ■ : ARB ; ■ : AGR ; ■ : SFE ; ■ : ZHU ; ■ : RIV ; ■ : RTE ; ■ : BTM et de la confiance : ■ : faibles → ■ : fortes valeurs, de la zone d'intérêt T33PUL.

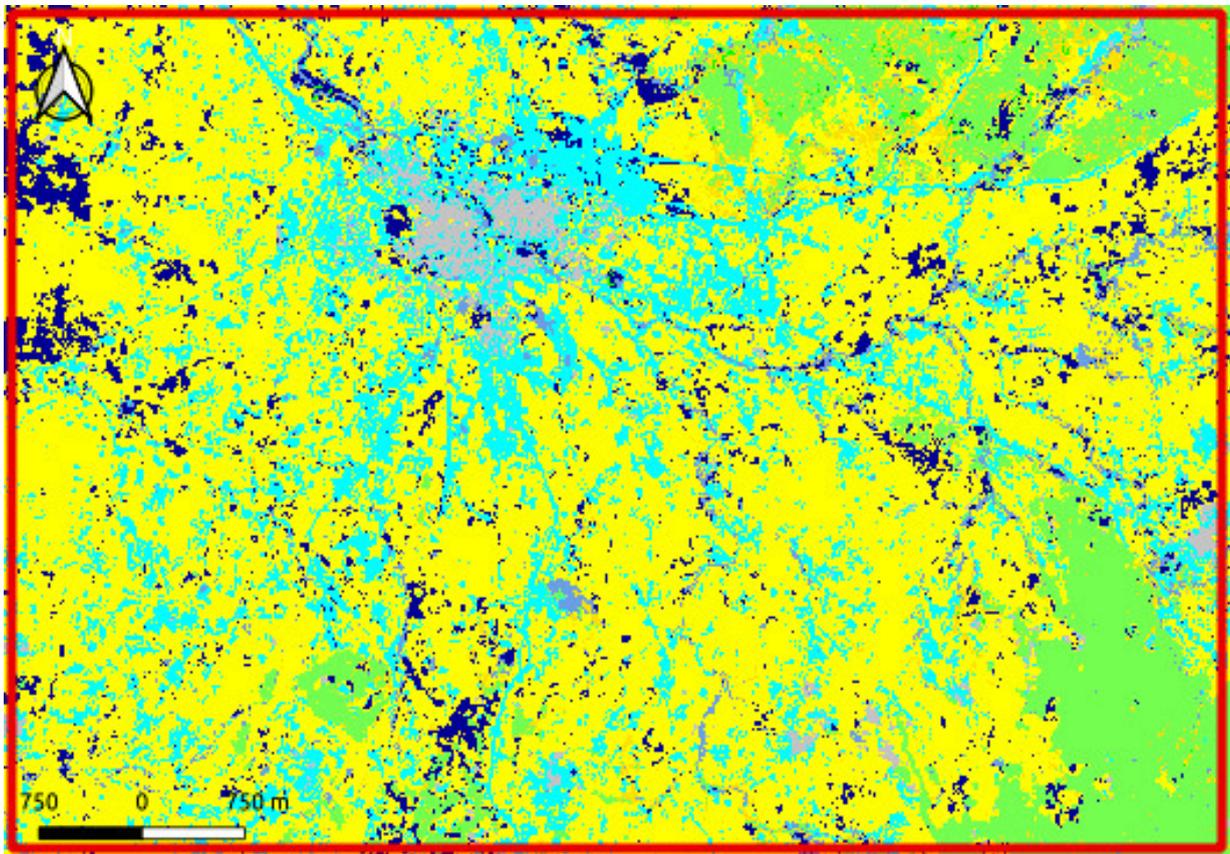


(A) Classification de la synthèse 2018_P105



(B) Confiance de la classification de la synthèse 2018_P105

FIG. 4.43 – Extraits de la classification supervisée de la synthèse 2018_P105 de séries temporelles d'images optiques Sentinel-2_L3A avec la légende à 9 classes : ■ : FRT ; ■ : PRA ; ■ : ARB ; ■ : AGR ; ■ : SFE ; ■ : ZHU ; ■ : RIV ; ■ : RTE ; ■ : BTM et de la confiance : ■ : faibles → ■ : fortes valeurs, de la zone d'intérêt T33PUL.



(A) Classification de la synthèse 2018_P165



(B) Confiance de la classification de la synthèse 2018_P165

FIG. 4.44 – Extraits de la classification supervisée de la synthèse 2018_P165 de séries temporelles d'images optiques Sentinel-2_L3A avec la légende à 9 classes : ■ : FRT; ■ : PRA; ■ : ARB; ■ : AGR; ■ : SFE; ■ : ZHU; ■ : RIV; ■ : RTE; ■ : BTM et de la confiance : ■ : faibles → ■ : fortes valeurs, de la zone d'intérêt T33PUL.

4.7.1.1 Evaluation quantitative

Les Figures 4.45 et 4.46 présentent respectivement les métriques de qualité globale pour l'année complète 2018 et les synthèses 2018_P45, 2018_P105, 2018_P165, 2018_P225 et 2018_P315 pour les trois légendes. Quelle que soit la légende utilisée, les valeurs de FS et de K sont globalement variables et faibles ($0,19 < FS < 0,39$ et $0,2 < K < 0,32$). **Les résultats les plus forts sont associés aux classifications de l'année complète 2018 pour les légendes à 5 et 9 classes et de la synthèse 2018_P225 pour la légende à 12 classes si l'on considère les FS et aux classifications de l'année complète 2018 et de la synthèse 2018_P315 pour la légende à 5 classes puis des synthèses 2018_P45 et 2018_P105 pour la légende à 9 classes et enfin 2018_P165 et 2018_P225 pour la légende à 12 classes si l'on considère les K.** Au contraire, les résultats les plus faibles sont associés aux classifications de la synthèse 2018_P315 si l'on considère les FS et de l'année complète 2018 si l'on considère les K pour la légende à 12 classes et aux classifications des synthèses 2018_P165 et 2018_P225 fondées respectivement sur les légendes à 5 et 9 classes à la fois du point de vue des FS et des K. Ces résultats montrent l'importance des fusions précoces (génération de synthèses et *gapfilling* dans *iota*²) des séries et synthèses de séries temporelles pour les classes VNC et VHB ainsi que des classes FOU et FFE de la légende à 12 classes qui s'y retrouvent mieux discriminées.

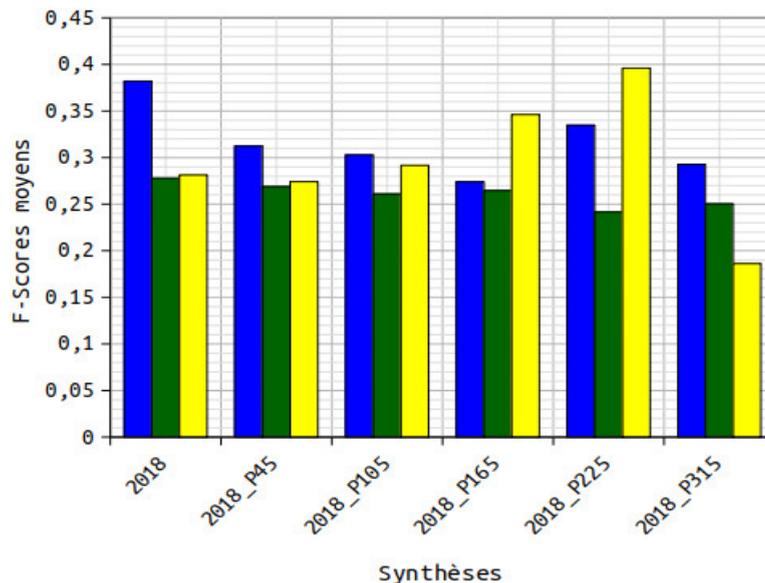


FIG. 4.45 – F-Scores moyens des classifications supervisées des différentes synthèses de séries temporelles d'images optiques Sentinel-2_L3A avec les légendes à 5 et 9 et 12 classes, de la zone d'intérêt T33PUL.

Les Figures 4.47, 4.48 et 4.49 présentent les métriques de qualité par classe des classifications supervisées des synthèses de séries temporelles d'images optiques Sentinel-2_L3A pour les légendes à 5, 9 et 12 classes respectivement. L'utilisation des légendes à 5 et 9 classes permet d'améliorer les classifications des synthèses 2018_P45 des classes RTE (FS (RTE) $\simeq 0,02$); BTM (FS (BTM) $\simeq 0,11$) et AGR (FS (AGR) $\simeq 0,82$) et 2018_P225 des classes VGT (FS (VGT) $\simeq 0,46$) et EAU (FS (EAU) $\simeq 0,36$) d'une part pour la légende à 5 classes et les classifications des synthèses 2018_P45 des classes PRA (FS (PRA) $\simeq 0,19$); AGR (FS (AGR) $\simeq 0,78$); SFE (FS (SFE) $\simeq 0,93$) et ZHU (FS (ZHU) $\simeq 0,17$) puis 2018_P315 des classes FRT (FS (FRT) $\simeq 0,05$) et RTE (FS (RTE) $\simeq 0,03$) et enfin de l'année complète 2018 des classes ARB (FS (ARB) $\simeq 0,34$) et BTM (FS (BTM) $\simeq 0,13$) d'autre part pour la légende à 9

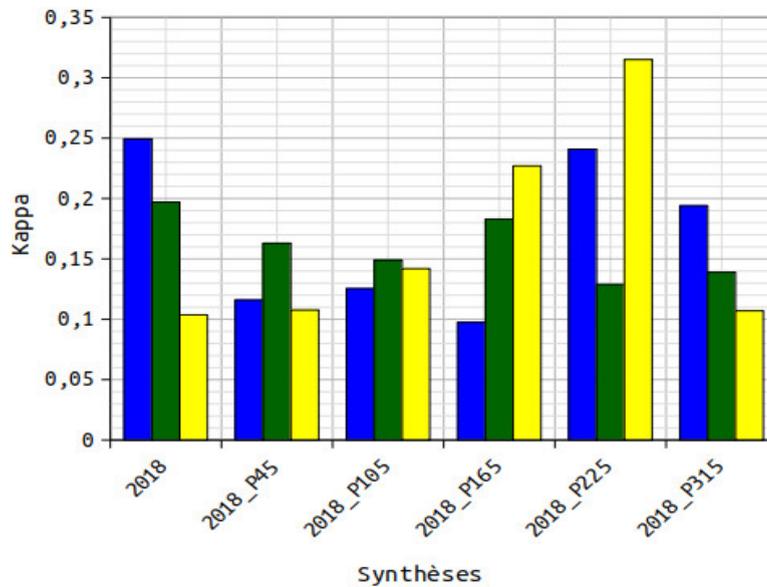


FIG. 4.46 – Coefficients Kappa des mêmes classifications que les FS dans la Figure 4.45.

classes. L'utilisation de la légende à 12 classes permet également d'améliorer les classifications des synthèses 2018_P225 des classes VHB (FS (VHB) $\simeq 0,34$); FOU (FS (FOU) $\simeq 0,5$); ZHH (FS (ZHH) $\simeq 0,6$); ZHU (FS (ZHU) $\simeq 0,25$); RIV (FS (RIV) $\simeq 0,17$); RTE (FS (RTE) $\simeq 0,2$) et BTM (FS (BTM) $\simeq 0,3$) puis 2018_P165 des classes VNC (FS (VNC) $\simeq 0,4$) et TCU (FS (TCU) $\simeq 0,48$) ensuite 2018_P105 des classes ARB (FS (ARB) $\simeq 0,41$) et SFE (FS (SFE) $\simeq 0,91$) et enfin de l'année complète 2018 de la classe FFE (FS (FFE) $\simeq 0,39$). **Les meilleurs résultats sont alors obtenus pour la légende à 9 classes, où le FS/classe atteint le FS (SFE) $\simeq 0,93$ de la classe SFE dans la classification de la synthèse 2018_P45 et les précisions PU et PP y atteignent respectivement la PU (AGR) $\simeq 0,96$ de la classe AGR et la PP (SFE) $\simeq 0,94$ de la classe SFE.**

La fusion des *BDs* améliore les résultats d'un plus grand nombre de classes (synthèses 2018_P45 et 2018_P225 pour les légendes à 9 et 12 classes respectivement). Par contre, ces performances sont de moins bonne qualité avec la synthèse 2018_P225 pour la légende à 12 classes. Ce résultat montre que l'ajout de *BDs* n'améliore pas la performance de classification d'une plus grande période de synthèse. Par conséquent, il serait plus judicieux de réduire la période de synthèse mensuelle des séries temporelles d'images optiques dans la classification d'un nombre élevé de classes d'OCS.

La fusion précoce d'un grand nombre de séries temporelles d'images de même que la fusion d'une *BDs* détaillée constituée des classes FRT; PRA et ARB dans la légende à 9 classes en une *BDs* compacte renfermant la classe VGT de la légende à 5 classes offrent de moins bons résultats. En effet, l'utilisation de la classe VGT diminue grandement les performances de la classification annuelle (FS = 0,38; PU (VGT) $\simeq 0,39$) pour la légende à 5 classes, alors que le FS de la classification de la synthèse 2018_P45 est de 0,95 lorsque les classes FRT; PRA et ARB sont considérées indépendamment (PU (FRT) $\simeq 0,03$; PU (PRA) $\simeq 0,11$ et PU (ARB) $\simeq 0,08$) pour la légende à 9 classes. Les valeurs de FS et de PU restent cependant de moins bonne qualité comparativement à la classification de la synthèse 2018_P45 pour la légende à 12 classes. **La fusion des classes FRT; PRA et ARB n'est donc pas pertinente en fusion précoce d'un nombre élevé de séries temporelles optiques, comme en attestent les faibles valeurs**

de FS de la classification annuelle pour la légende à 5 classes. Dans ce cas, la fusion des classes d'OCS induit davantage de bruits que d'étiquettes utiles.

Les faibles performances des paires de classes (RIV et RTE) et (ZHU et BTM) dans les classifications annuelle et de synthèses pour les légendes à 9 et 12 classes proviennent des réflectances des différentes classes. En effet, **les éléments agro-naturels issus de chacune des deux paires de classes, peuvent avoir des réflectances très proches durant les périodes de classification.** On rejoint ainsi des conclusions déjà formulées plus haut.

4.7.1.1.1 Cas particulier de classifications de synthèses de période P45 sur la zone d'intérêt T33PUL

Les Figures 4.50 et 4.51 présentent respectivement les métriques de qualité globale pour les synthèses de période P45 de séries temporelles d'images optiques Sentinel-2_L3A pour les trois légendes. Les valeurs de FS et de K pour les images optiques sont variables et faibles ($0,02 < FS < 0,31$ et $0,18 < K < 0,24$). **Les résultats les plus forts sont associés aux classifications des synthèses septembre_P45 pour la légende à 12 classes et 2018_P45 pour les légendes à 5 et 9 classes si l'on considère les FS et aux classifications des synthèses mensuelles mars_P45, juin_P45 et septembre_P45 pour les légendes à 12, 9 et 5 classes respectivement si l'on considère les K.** Au contraire, les résultats les plus faibles sont associés aux classifications des synthèses juillet_P45 si l'on considère les FS et mai_P45 si l'on considère les K pour la légende à 9 classes et août_P45 si l'on considère les FS et les K pour les légendes à 5 et 12 classes. Ces résultats montrent que les légendes à 5 et 9 classes donnent de bonnes performances aux classifications produites avec la majorité des synthèses de périodes P45 contrairement à la légende à 12 classes qui offrent de faibles résultats avec ces synthèses comme par exemple la synthèse août_P45. Ainsi, les classes d'OCS constitutives des légendes à 5 et 9 classes se trouvent mieux discriminées dans les classifications des synthèses de période P45.

La Figure 4.52 présente les métriques de qualité par classe pour les synthèses de période P45 de séries temporelles d'images optiques Sentinel-2_L3A pour la légende à 5 classes. L'utilisation de cette légende permet d'améliorer les classifications de la synthèse 2018_P45 des classes RTE (FS (RTE) $\simeq 0,03$); BTM (FS (BTM) $\simeq 0,11$) et AGR (FS (AGR) $\simeq 0,82$). De plus, les classes VGT (FS (VGT) $\simeq 0,44$) et EAU (FS (EAU) $\simeq 0,41$) sont respectivement améliorées dans les classifications des synthèses septembre_P45 et mars_P45 pour la légende à 5 classes.

Afin de permettre l'analyse détaillée en comparant par paire de classes **des erreurs de classification utilisant le scénario STR3(P45)B avec la synthèse 2018_P45 de séries temporelles d'images optiques par rapport au scénario STR12B se fondant sur les séries temporelles elles-mêmes de l'année complète 2018**, les Tableaux 4.24, 4.25 et 4.26 présentent les matrices de confusion des classifications supervisées de la synthèse 2018_P45 utilisant respectivement les légendes à 5, 9 et 12 classes sur la zone d'intérêt T33PUL. Pour toutes les légendes, il existe quelques confusions qui reviennent entre les classes malgré la fusion précoce des synthèses mensuelles de période P45 (2018_P45) de séries temporelles d'images optiques seules. Dans ces tableaux, les pixels identifiés en classe VGT se trouvent davantage classifiés en AGR et le taux de FP, avec la classe AGR, augmente ici de 38,9% à 44,7% avec l'utilisation de la synthèse 2018_P45 de séries d'images optiques Sentinel-2 pour la légende à 5 classes. La confusion s'atténue plutôt avec l'utilisation des classes FRT et ARB, et les taux de FP baissent de 14,5% à 4,6% pour la classe FRT et de 17,3% à 12,4% pour la classe ARB. Par contre, la confusion s'accroît avec l'utilisation de la classe PRA, et le taux de FP augmente fortement de 13% à 34,2%. Concernant la confusion avec la classe EAU, elle s'accroît et les taux de FP augmentent pour les

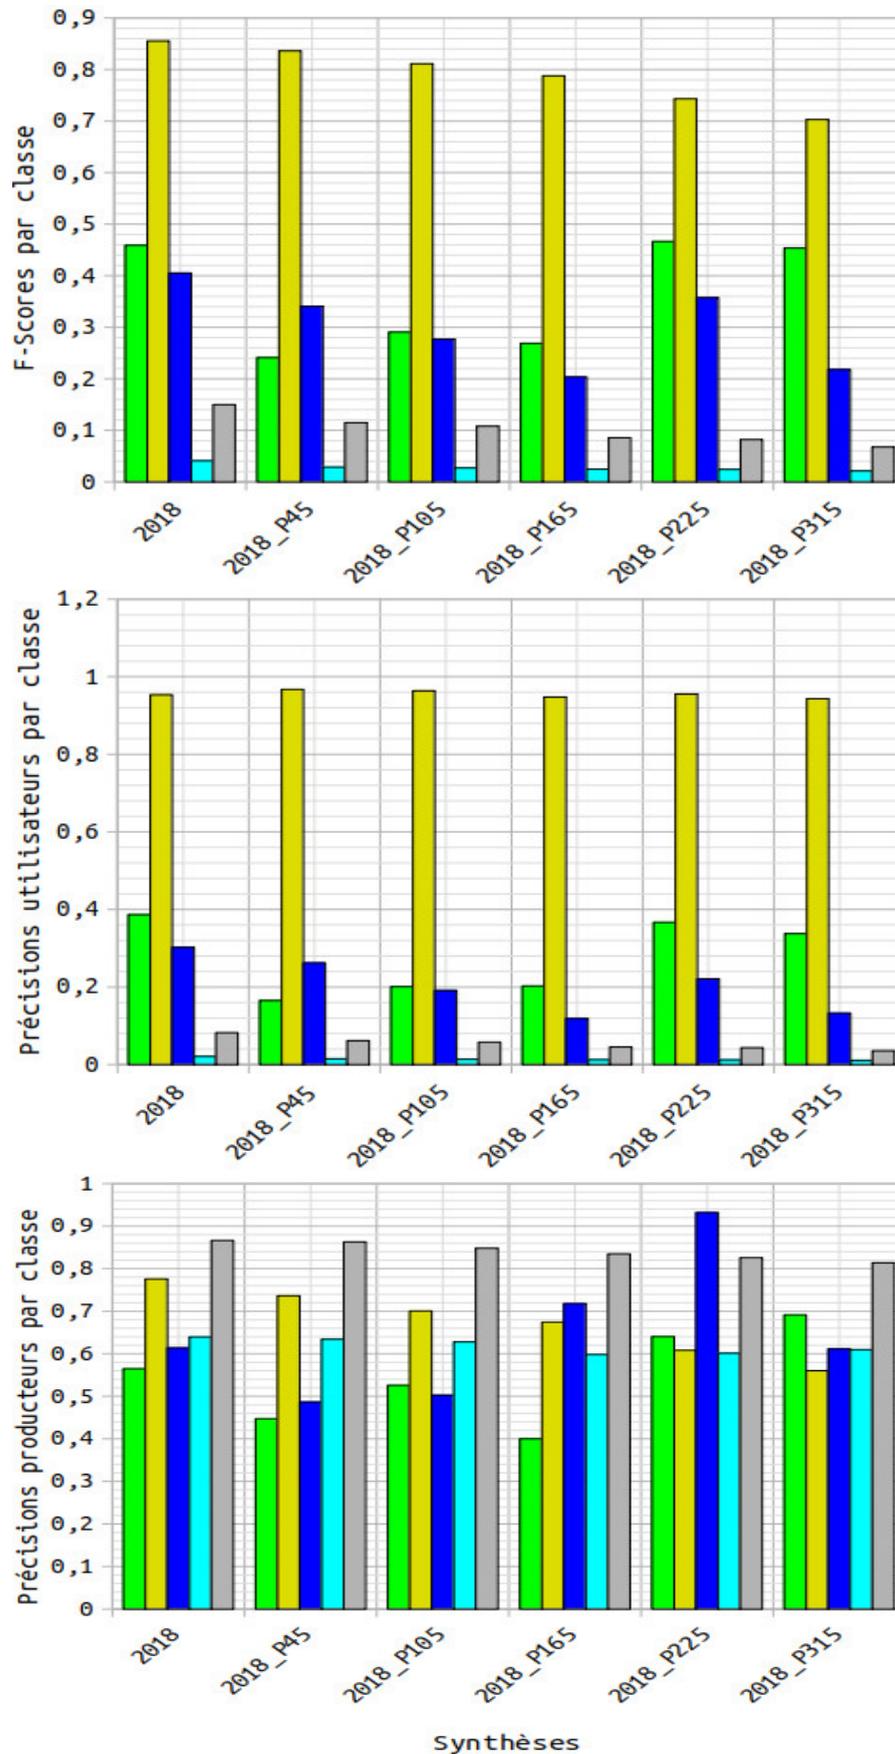


FIG. 4.47 – F-Scores et précision utilisateur et précision producteur par classe des classifications supervisées des synthèses de séries temporelles d'images optiques Sentinel-2_L3A avec la légende à 5 classes : ■ : VGT; ■ : AGR; ■ : EAU; ■ : RTE; ■ : BTM, de la zone d'intérêt T33PUL.

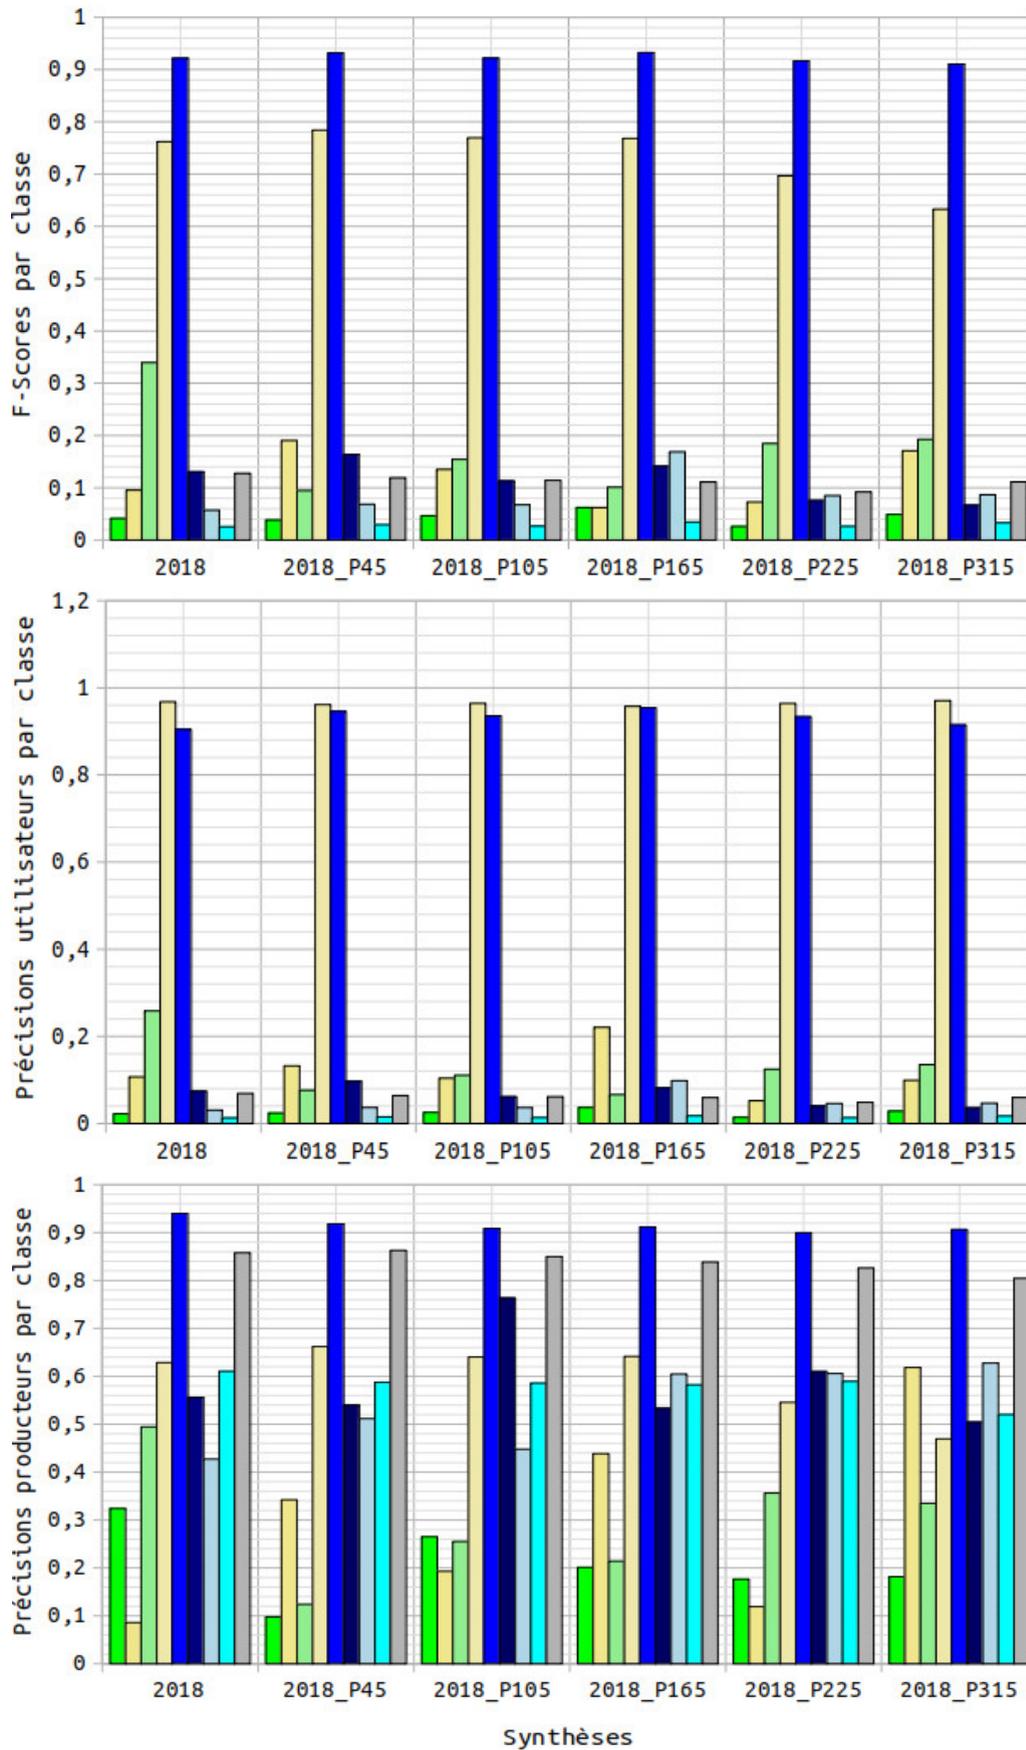


FIG. 4.48 – F-Scores et précision utilisateur et précision producteur par classe des classifications supervisées des synthèses de séries temporelles d’images optiques Sentinel-2_L3A avec la légende à 9 classes : ■ : FRT ; ■ : PRA ; ■ : ARB ; ■ : AGR ; ■ : SFE ; ■ : ZHU ; ■ : RIV ; ■ : RTE ; ■ : BTM, de la zone d’intérêt T33PUL.

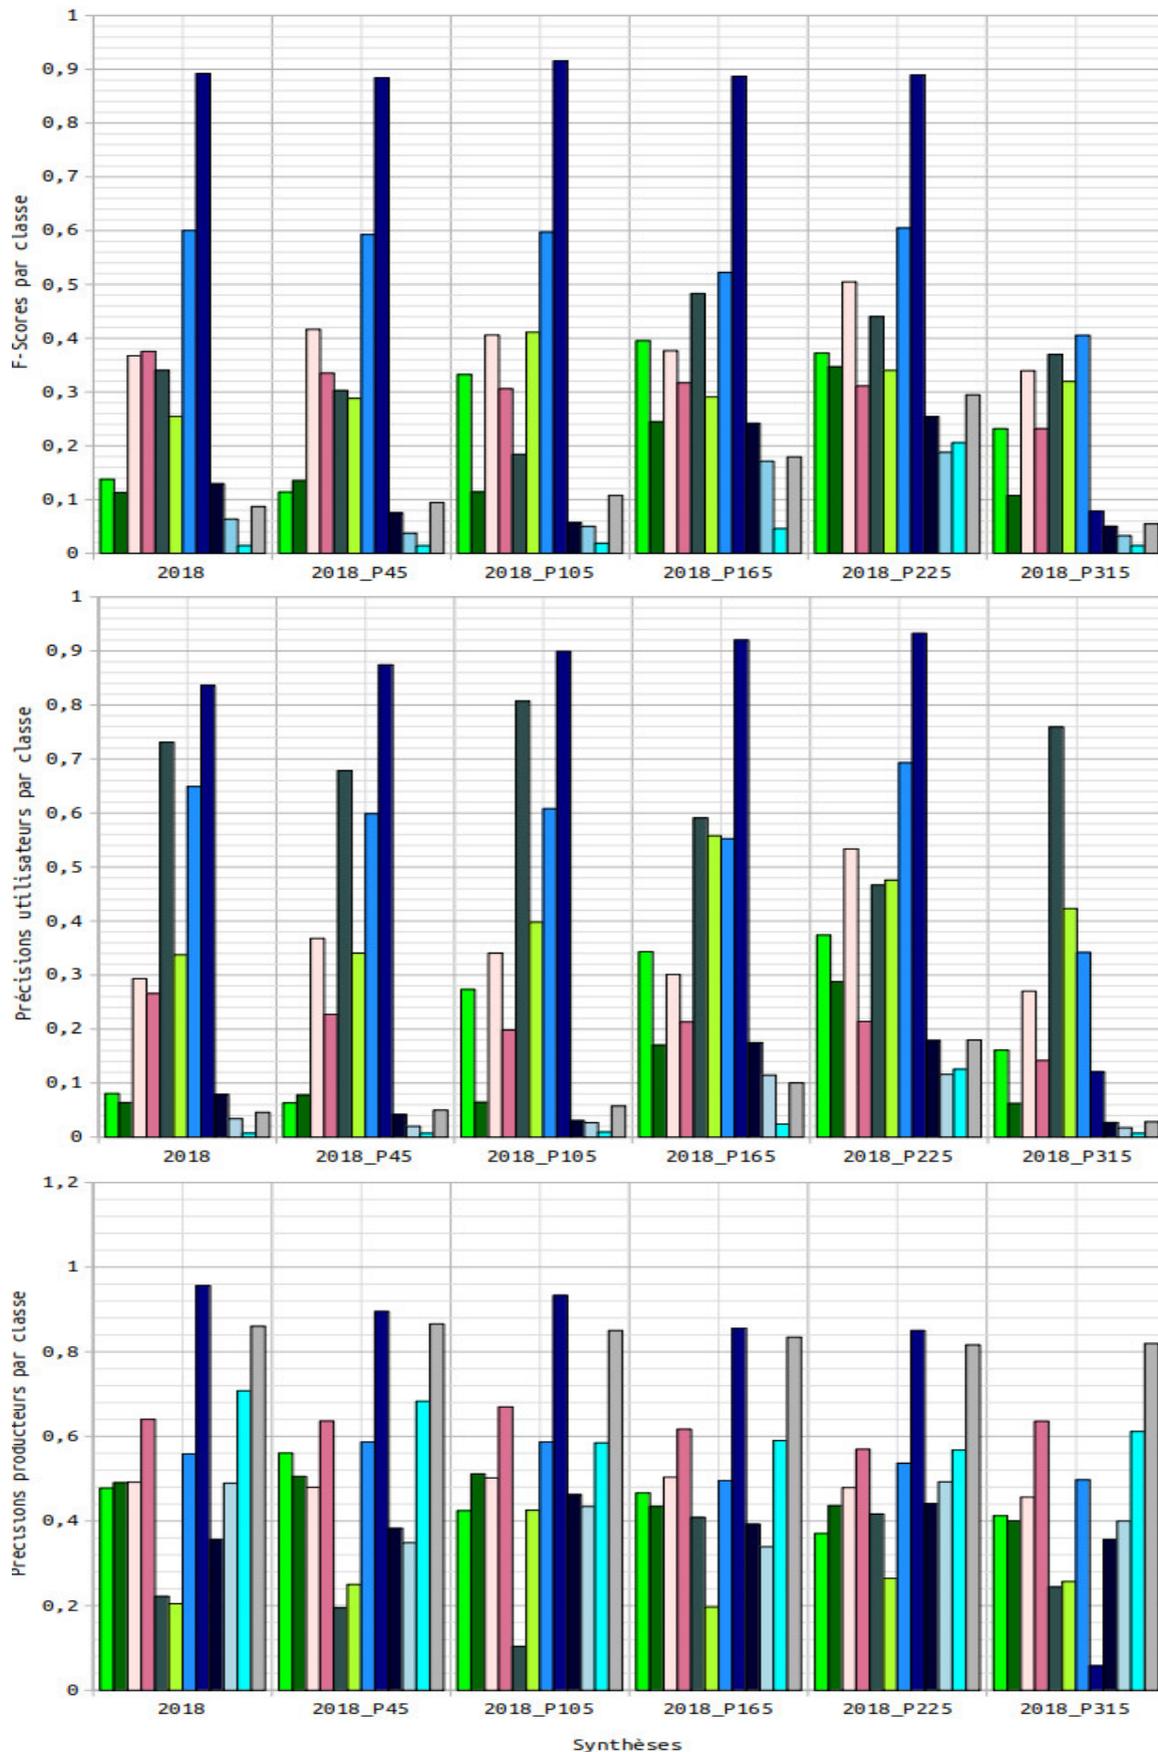


FIG. 4.49 – F-Scores et précision utilisateur et précision producteur par classe des classifications supervisées des synthèses de séries temporelles d’images optiques Sentinel-2_L3A avec la légende à 12 classes : ■ : VNC; ■ : VHB; ■ : FOU; ■ : FFE; ■ : TCU; ■ : ARB; ■ : ZHH; ■ : SFE; ■ : ZHU; ■ : RIV; ■ : RTE; ■ : BTM, de la zone d’intérêt T33PUL.

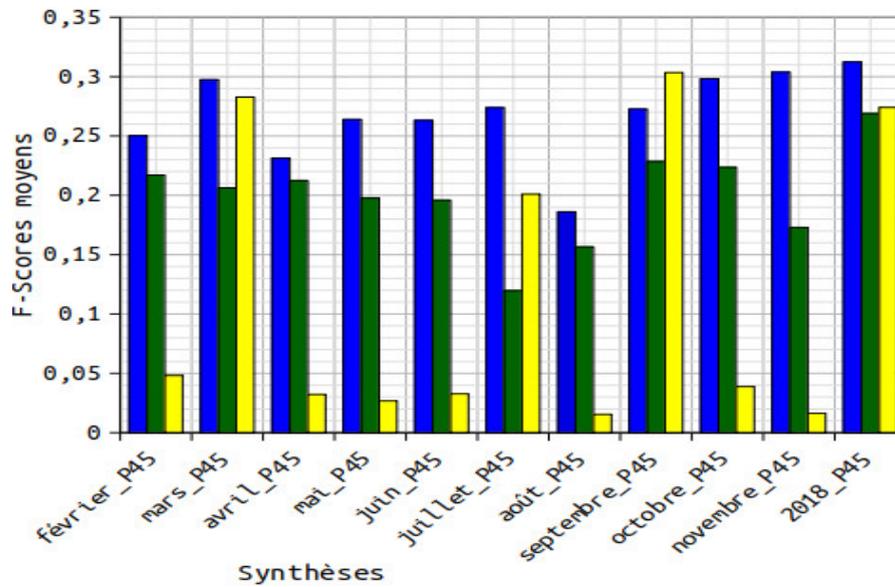


FIG. 4.50 – F-Scores moyens des classifications supervisées des synthèses de période *P45* de séries temporelles d’images optiques Sentinel-2_L3A avec les légendes à 5 : ■ : OSM et 9 : ■ : OSM+INC et 12 : ■ : OSM+INC+GLC classes, de la zone d’intérêt T33PUL.

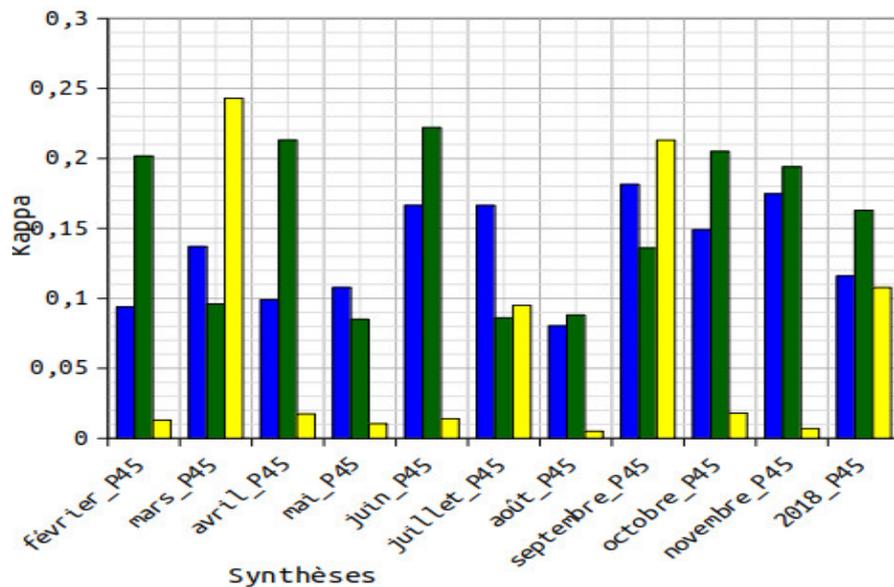


FIG. 4.51 – Coefficients Kappa des mêmes classifications que les FS dans la Figure 4.50.

légendes à 5 et 9 classes. Cependant, cette confusion devient très faible avec l’ajout de nouvelles classes pour la légende à 12 classes. C’est ainsi que **la confusion entre les classes VNC et RIV s’atténue fortement avec un taux de FP qui baisse drastiquement de 38,3% à 8,5%. Cette diminution de FP se faisant au détriment des FN, avec une forte augmentation de ceux-ci lors de l’utilisation de la synthèse 2018_P45 de séries d’images optiques seules.**

Par ailleurs, avec la synthèse 2018_P45 de séries d’images optiques pour la légende à 5 classes sur la zone d’intérêt T33PUL, la classe RTE est classifiée en AGR avec un taux de $FP=22,3\%$. À l’inverse, la classe AGR est classifiée en RTE avec un taux inférieur de $FN=15\%$. Ce taux baisse et devient $FN=14,8\%$ contrairement au taux de FP qui augmente légèrement et devient $FP=22,8\%$ et la confusion

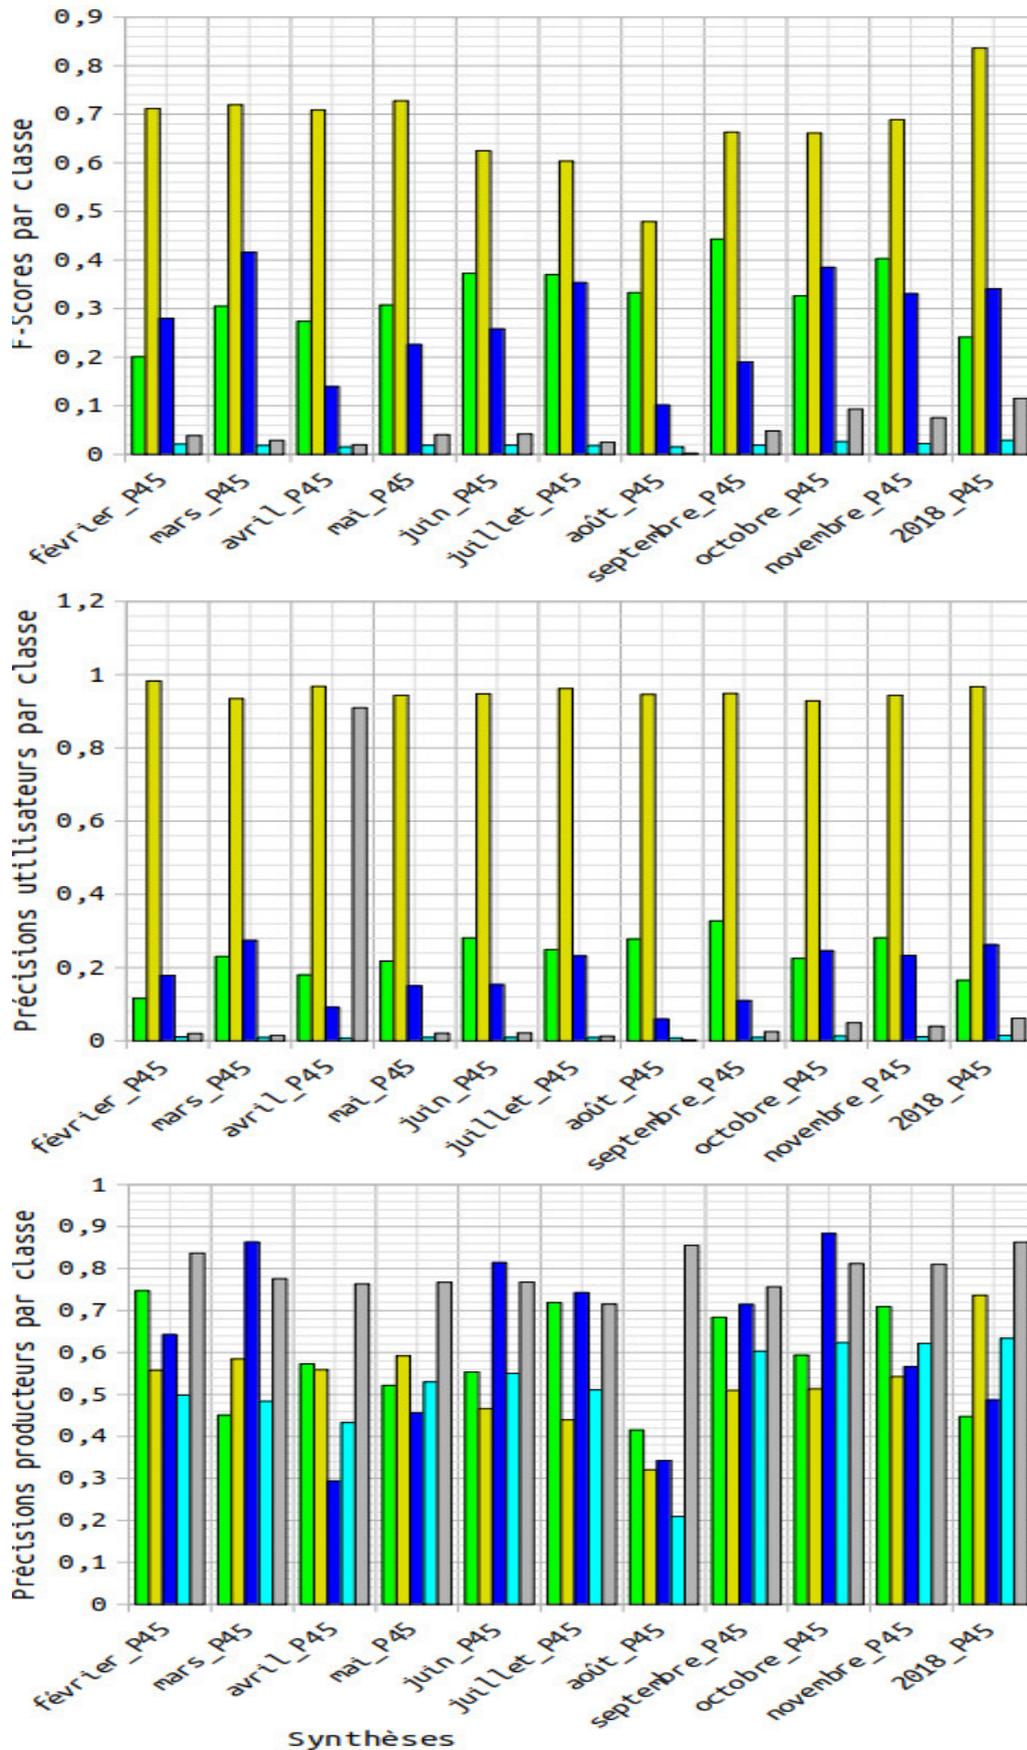


FIG. 4.52 – F-Scores et précision utilisateur et précision producteur par classe des classifications supervisées des synthèses de période P45 de séries temporelles d'images optiques Sentinel-2_L3A avec la légende à 5 classes : ■ : VGT; ■ : AGR; ■ : EAU; ■ : RTE; ■ : BTM, de la zone d'intérêt T33PUL.

s'accroît donc très peu pour la légende à 9 classes. De plus, pour cette légende, les classes SFE et RIV sont classifiées en RTE et ARB avec des taux de $FP=0,1\%$ et $FP=7,7\%$ respectivement. Inversement, les classes RTE et ARB sont classifiées en SFE et RIV avec des taux inférieurs de $FN=0\%$ pour la paire de classes (SFE et RTE) et supérieur de $FN=9,9\%$ pour la paire (RIV et ARB). Ce taux reste constant pour (SFE et RTE) et baisse ($FN=3,2\%$) pour (RIV et ARB) de même que le taux de FP demeure constant pour (SFE et RTE) et baisse ($FP=2,2\%$) pour (RIV et ARB). Ainsi, la confusion ne s'atténue pas pour la paire de classes (SFE et RTE) contrairement à la paire (RIV et ARB) pour laquelle la discrimination est meilleure pour la légende à 12 classes. En outre, pour la légende à 9 classes, la classe RTE est classifiée en RIV avec un petit taux de $FP=1,2\%$. À l'inverse, la classe RIV est classifiée en RTE avec un taux fortement supérieur de $FN=6,2\%$. Ce taux baisse à $FN=5,1\%$ contrairement au taux de FP qui augmente et devient $FP=1,6\%$ et la confusion s'accroît pour la paire de classes (RTE et RIV) pour la légende à 12 classes. En général, **les taux de FN augmentent grandement et la discrimination des classes d'OCS est meilleure à quelques exceptions près telles que les paires de classes (SFE et RTE) et (RTE et RIV) dont les confusions sont toujours présentes même si elles sont assez réduites ici en utilisant la synthèse 2018_P45 de séries temporelles d'images optiques Sentinel-2_L3A seules pour les légendes à 9 et 12 classes.**

TAB. 4.24 – Matrice de confusion de la synthèse 2018_P45 avec la légende à 5 classes.

L3A_P45		Vérité Terrain					PU
% VU	CL	VGT	AGR	EAU	RTE	BTM	
11,8	VGT	47,8	8,9	8,0	3,0	0,3	16,5
77,1	AGR	44,7	73,6	37,6	22,3	3,3	96,7
2,2	EAU	2,0	1,7	48,7	0,4	0,1	26,2
0,1	RTE	5,1	15,0	4,5	63,4	10,1	1,5
0,1	BTM	0,4	0,8	1,2	11,0	86,3	6,2
	PP	47,8	73,6	48,7	63,4	86,3	

TAB. 4.25 – Matrice de confusion de la synthèse 2018_P45 avec la légende à 9 classes.

L3A_P45		Vérité Terrain									PU
% VU	CL	FRT	PRA	ARB	AGR	SFE	ZHU	RIV	RTE	BTM	
0,8	FRT	77,2	14,8	4,9	3,6	0,4	2,7	1,6	1,1	0,2	2,4
7,4	PRA	9,8	41,6	32,5	3,6	0,1	1,8	6,1	1,1	0,2	13,2
4,1	ARB	5,6	7,9	34,4	5,0	0,1	2,1	7,7	2,4	0,4	7,6
77,1	AGR	4,6	34,2	12,4	66,2	0,5	25,2	14,1	22,8	3,2	96,1
4,2	SFE	0,0	0,0	0,0	0,1	91,8	5,4	0,8	0,0	0,0	94,6
0,9	ZHU	1,5	0,2	3,6	4,5	3,1	54,0	10,2	1,4	0,2	9,7
0,2	RIV	0,7	0,3	9,9	1,6	3,9	6,3	51,2	1,2	0,2	3,7
0,1	RTE	0,6	0,9	2,1	14,8	0,1	1,9	6,2	58,8	9,2	1,5
0,1	BTM	0,1	0,1	0,3	0,7	0,0	0,6	2,1	11,2	86,3	6,4
	PP	77,2	41,6	34,4	66,2	91,8	54,0	51,2	58,8	86,3	

TAB. 4.26 – Matrice de confusion de la synthèse 2018_P45 avec la légende à 12 classes.

L3A_P45		Vérité Terrain												PU
% VU	CL	VNC	VHB	FOU	FFE	TCU	ARB	ZHH	SFE	ZHU	RIV	RTE	BTM	
0,1	VNC	56,3	0,4	0,0	0,0	0,0	0,0	1,1	0,0	0,0	12,6	0,0	0,0	6,3
0,6	VHB	14,2	50,5	3,8	0,4	12,0	9,3	11,8	1,2	30,4	13,6	4,0	0,6	7,8
4,5	FOU	0,0	7,0	48,0	30,5	1,1	24,1	0,8	0,6	6,5	4,2	0,7	0,1	36,8
0,5	FFE	0,0	1,9	21,6	63,6	0,0	2,4	0,0	0,3	0,3	1,6	0,1	0,0	22,7
45,0	TCU	0,0	5,9	3,3	0,4	41,3	25,0	0,7	0,0	1,9	3,4	7,6	1,1	67,8
18,2	ARB	0,3	5,5	18,7	4,4	12,7	27,7	0,5	0,0	2,1	2,2	4,4	0,7	34,0
11,5	ZHH	11,4	3,5	0,2	0,1	0,2	0,1	58,7	4,6	13,4	8,9	0,1	0,0	59,9
4,2	SFE	2,4	0,4	0,2	0,0	0,1	0,0	12,1	89,5	0,6	2,9	0,0	0,0	87,4
0,9	ZHU	6,8	6,5	2,1	0,1	7,7	1,4	7,2	3,1	38,3	9,3	1,4	0,2	4,2
0,2	RIV	8,5	8,5	1,5	0,4	4,3	3,2	6,0	0,5	3,6	34,9	1,6	0,4	2,0
0,1	RTE	0,4	8,7	0,6	0,0	19,5	6,4	0,8	0,1	2,8	5,1	68,3	10,3	0,7
0,1	BTM	0,1	1,1	0,1	0,0	1,2	0,3	2,8	0,0	0,2	1,3	11,8	86,6	5,0
	PP	56,3	50,5	48,0	63,6	41,3	27,7	58,7	89,5	38,3	34,9	68,3	86,6	

% VU : pourcentage de données vecteurs utilisées.

CL : classification.

4.7.1.2 Utilisation des confiances des classifications supervisées de la zone d'intérêt T33PUL

Les Figures 4.42B, 4.43B et 4.44B montrent les extraits de cartes de confiance respectives des extraits de classifications supervisées des synthèses 2018_P45, 2018_P105 et 2018_P165 pour la légende à 9 classes, de la zone d'intérêt T33PUL produites dans les Figures 4.42A, 4.43A et 4.44A.

Outre le nombre de dates pour lesquelles chaque pixel est valide et la légende, on peut constater, ici, que la confiance est également influencée par la période de synthèse de séries temporelles d'images optiques Sentinel-2. En effet, **les valeurs de confiance diminuent globalement lorsque la période de synthèse augmente. Par contre, la confiance se trouve renforcée localement lorsque la période de synthèse augmente comme c'est le cas pour les périodes P105 et P165 pour lesquelles les classes ARB; SFE; ZHU; RTE et BTM possèdent les valeurs de confiance les plus élevées.** En effet, la fusion précoce (génération de synthèses) a permis de se débarrasser de quelques résidus de nuages et leurs ombres et d'améliorer localement la confiance de classification des classes d'OCS avec les synthèses de grandes périodes. C'est ainsi que la classe ARB est par exemple facilement reconnaissable dans la partie sud-est de la Figure 4.44B.

4.7.1.3 Évaluation qualitative sur la zone d'intérêt T33PUL

Les métriques quantitatives sur une très grande surface n'étant pas en mesure de révéler plusieurs types d'erreurs présentes dans les cartes d'OCS du fait aussi de la qualité de la synthèse générée en plus de celle de la donnée de référence, une évaluation visuelle permet d'identifier différents problèmes qui sont analysés dans cette section.

4.7.1.3.1 Paysages difficiles dans les classifications supervisées de la zone d'intérêt T33PUL

L'étude comparative des classifications des trois synthèses 2018_P45, 2018_P105 et 2018_P165 pour la légende à 9 classes permet de mettre en évidence l'avantage de la classification supervisée d'une synthèse de séries temporelles d'images Sentinel-2 sur des zones fragmentées ou les régions à topographie irrégulière qui sont très souvent couvertes d'un pourcentage important de nuages et d'ombres qui les rendent beaucoup plus difficiles à cartographier correctement que les zones plates avec de grands paysages homogènes. En effet, les zones de faibles confiances sont beaucoup plus réduites tandis que celles de fortes valeurs de confiances sont davantage accentuées dans la classification supervisée d'une

synthèse. Ceci est dû à la meilleure qualité des classifications supervisées des classes d'OCS avec la synthèse *2018_P165*, ce qui ne ressort pas forcément pour la synthèse *2018_P45*. Ainsi, les résultats de classification sont étudiés en détail dans cette section sur deux types de zones : **une zone rurale (Figure 4.53) et une zone urbaine (Figure 4.54).**

La zone rurale de la Figure 4.53A est la même que celle décrite dans la Figure 4.13A. Les différentes classifications et confiances de classification des synthèses *2018_P45*, *2018_P105* et *2018_P165* uniquement pour la légende à 9 classes sont représentées sur les Figures 4.53B-F. Ici, les classes PRA et ARB se distinguent mieux pour la synthèse *2018_P165* sur la Figure 4.53C : **la classification de la synthèse *2018_P165* permet dans ce cas de mieux discriminer les classes de végétation contrairement à celle de la synthèse *2018_P45* qui ne permet pas d'identifier clairement les classes de végétation.** On peut également noter que la confusion entre les classes ARB et SFE est réduite. Sur la Figure 4.53C (synthèse *2018_P165*), la classification de la classe BTM est meilleure. En effet, les bâtiments ressortent clairement et précisément, il y a toutefois un peu de confusion avec la classe RTE. De la même manière, la classe RTE est assez bien représentée dans la classification de la synthèse *2018_P105* (Figure 4.53B). Cependant, mise à part ces quatre classes, les autres posent encore problème. Par exemple, la classe ZHU qui contient des zones d'ombres est confondue partiellement avec la classe ARB dans la classification de la synthèse *2018_P165* (Figure 4.53C). De même, la classe RIV est confondue presque intégralement avec la classe RTE dans la classification de la synthèse *2018_P45* (Figure 4.53D).

Les classifications des synthèses *2018_P45*, *2018_P105* et *2018_P165* des Figures 4.54A-C(D) sont effectuées pour la légende à 9 classes sur la zone urbaine décrite dans la Figure 4.14B. Pour la synthèse *2018_P45*, la classification des classes RTE et BTM (Figure 4.54A) donne de plus bons résultats permettant de mieux les distinguer avec des confusions minimales apparaissant entre ces classes. Cette dernière synthèse a permis de séparer les zones mixtes découlant de polygones grossiers au sein des données d'apprentissage et d'améliorer la qualité de la classification. De même, les classes ZHU et RIV sont détectées distinctement dans la classification de la synthèse *2018_P105* (Figure 4.54B). De plus, la classification de ces quatre classes donne de meilleurs résultats pour la synthèse *2018_P165* (Figure 4.54C(D)), même si les classes RIV et RTE se confondent toujours à certains petits endroits. **Cette confusion, que l'on avait déjà observée sur la zone rurale, pourrait être facilement supprimée par exemple en utilisant les synthèses mensuelles de séries temporelles de la combinaison d'images optiques et radar Sentinel-1_L1/-2_L3A.**

4.7.1.3.2 Petites classes locales dans les classifications supervisées de la zone d'intérêt *T33PUL*

Les classes minoritaires sont difficiles à cartographier en raison de leur manque de représentativité lors de l'entraînement des classifieurs. Des exemples typiques sont les classes RTE ; BTM ; RIV et ZHU. Ces classes sont également concentrées dans des régions spécifiques de la zone d'intérêt *T33PUL*. La Figure 4.55C illustre comment **la classification de la synthèse *2018_P165* réduit la confusion entre les classes ZHU et RTE.**

4.7.1.4 Comparaison pixel à pixel sur la zone d'intérêt *T33PUL*

Les Tableaux 4.27 et 4.28 présentent les différentes valeurs de K et du FS avec les différentes synthèses mensuelles de périodes 105 et 165 jours et leurs fusions précoces respectives *2018_P105* et *2018_P165* de séries temporelles d'images optiques Sentinel-2_L3A et de la vérité terrain (*VT*) pour la légende à 9 classes, de la zone d'intérêt *T33PUL*. On observe que toutes les classifications des synthèses de périodes 105 et 165 jours ne s'accordent pas avec la *VT*. De plus, on peut remarquer de très faibles scores de

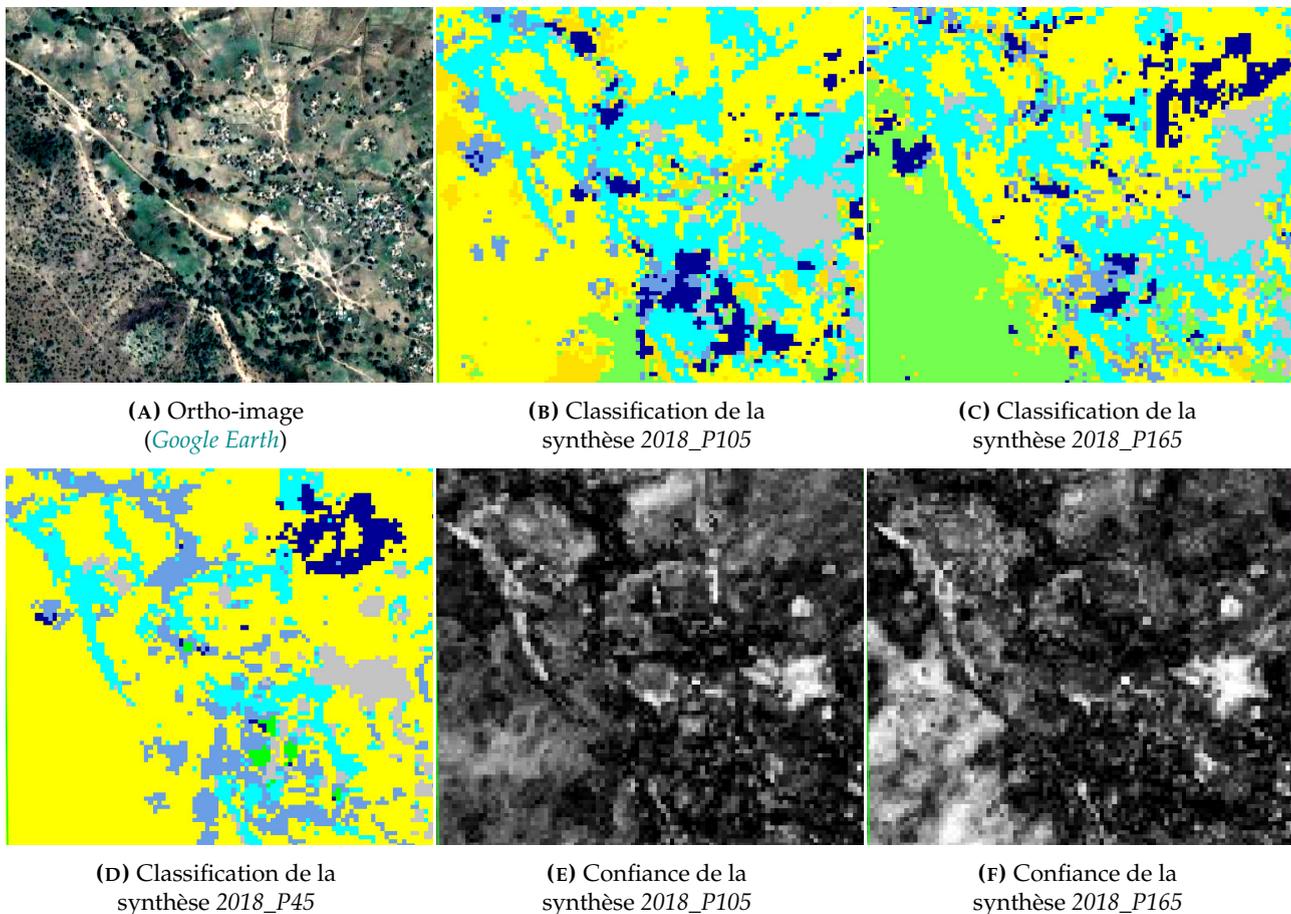


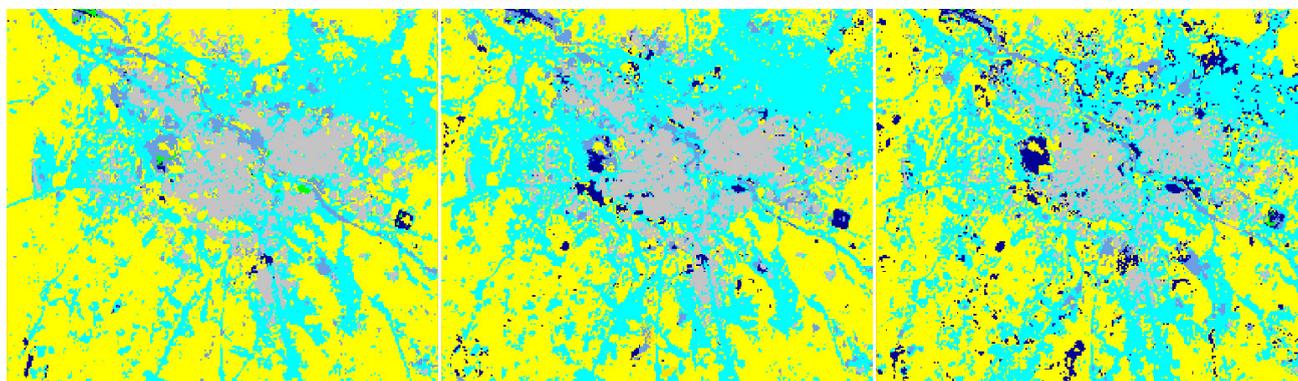
FIG. 4.53 – Extraits de l’ortho-image et des classifications et des confiances de classifications des synthèses 2018_P45 et 2018_P105 et 2018_P165 de séries d’images optiques Sentinel-2_L3A avec la légende à 9 classes, d’une zone rurale sur la zone d’intérêt T33PUL.

similarité K et FS issus de la comparaison de la classification de la synthèse mensuelle juillet_P105 par rapport aux autres classifications de synthèses et la VT. **Les valeurs de K et de FS sont plus élevées dans chacune des classifications des synthèses (septembre_P105, novembre_P105 et 2018_P105) de période 105 jours et (avril_P165 et octobre_P165) de période 165 jours par rapport aux autres classifications des synthèses aux périodes respectives et la VT qui possèdent ainsi les meilleurs taux d’accord.** Au contraire, les classifications des synthèses mensuelles mars_P105 et juillet_P165 possèdent les piètres taux d’accord par rapport au reste des classifications des synthèses de périodes respectives 105 et 165 jours et la VT.

4.7.1.5 Comparaison par région des distributions de classes sur la zone d’intérêt T33PUL

L’objectif de cette section est de comparer en effectuant la moyenne des scores calculés au sein de grandes régions extraites des classifications de synthèses de séries temporelles d’images optiques de la zone d’intérêt T33PUL.

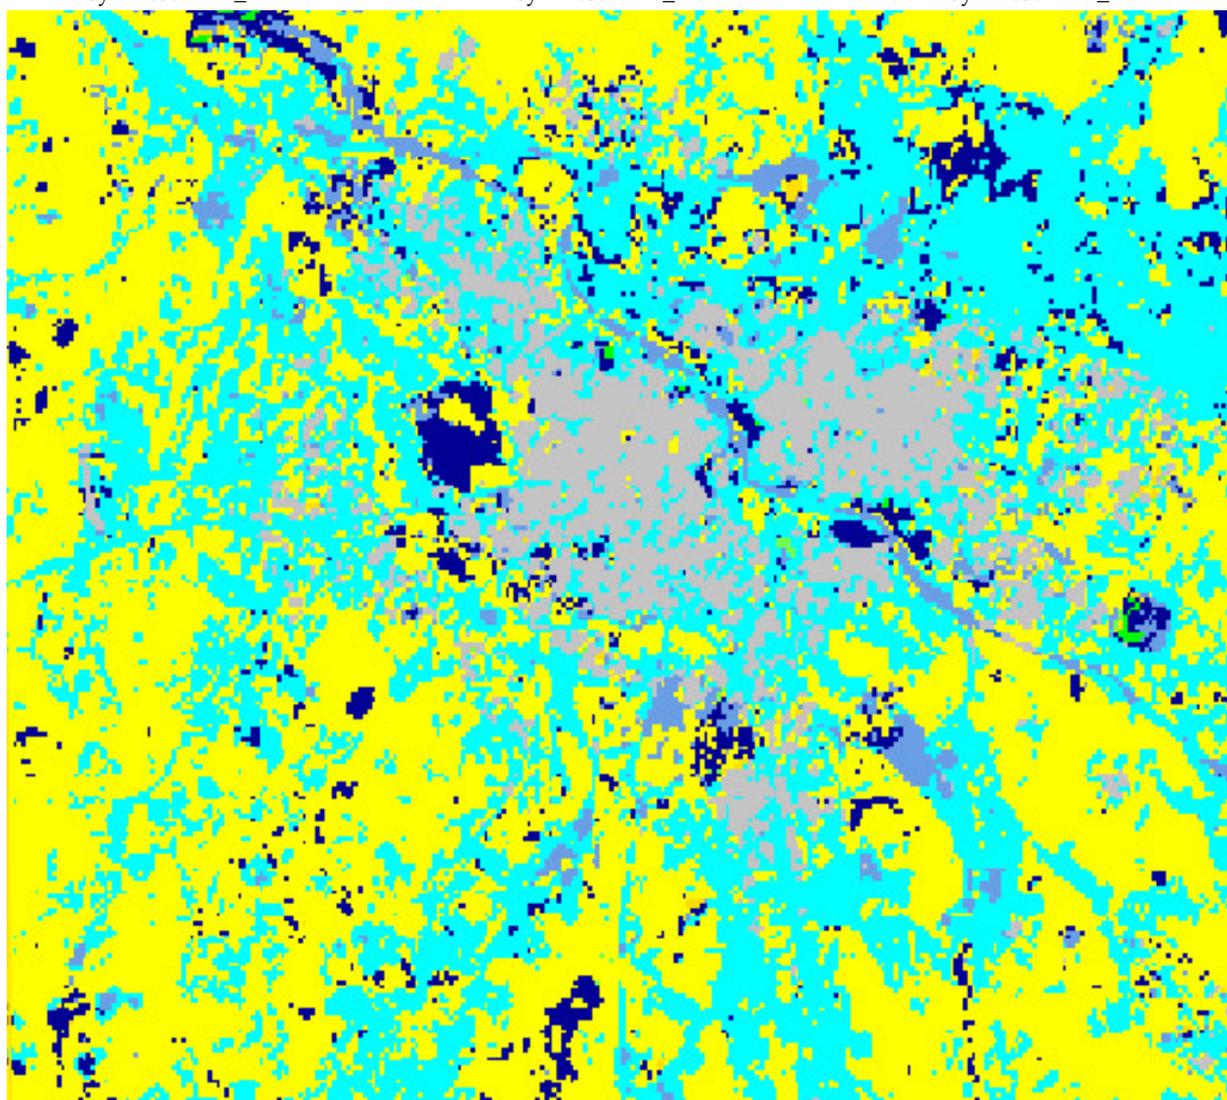
Les Tableaux 4.29 et 4.30 présentent les moyennes des scores calculés au sein de cellules de taille 200 pixels extraites des classifications supervisées des synthèses respectives de périodes 105 et 165 jours de séries temporelles d’images optiques Sentinel-2_L3A et de la vérité terrain (VT) pour la légende à 9 classes, de la zone d’intérêt T33PUL.



(A) Classification de la synthèse 2018_P45

(B) Classification de la synthèse 2018_P105

(C) Classification de la synthèse 2018_P165



(D) Zoom sur l'extrait de la classification de la synthèse 2018_P165

FIG. 4.54 – Extraits des classifications des synthèses 2018_P45 et 2018_P105 et 2018_P165 de séries temporelles d'images optiques Sentinel-2_L3A avec la légende à 9 classes :
 ■ : FRT; ■ : PRA; ■ : ARB; ■ : AGR; ■ : SFE; ■ : ZHU; ■ : RIV; ■ : RTE; ■ : BTM, d'une zone urbaine sur la zone d'intérêt T33PUL.

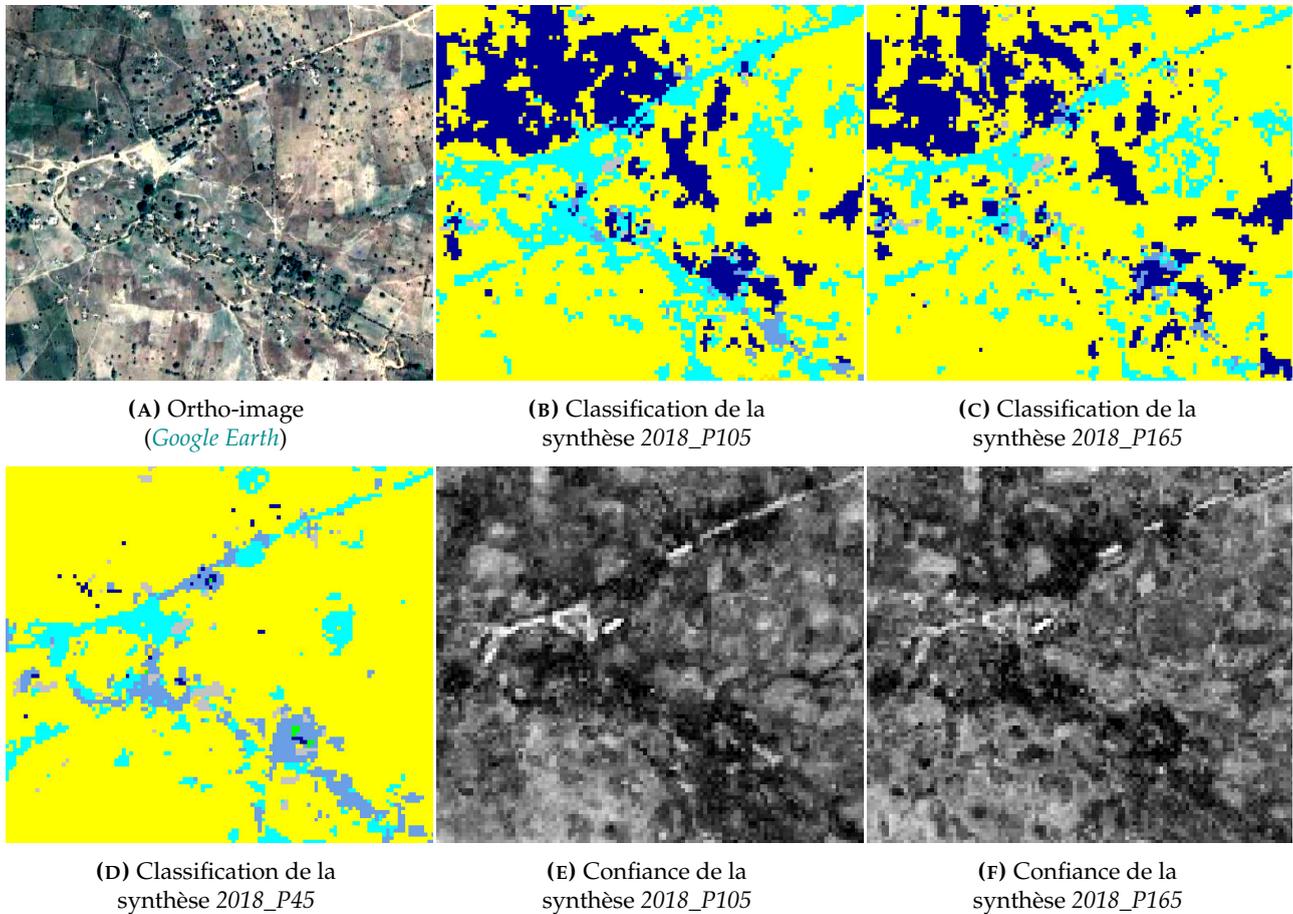


FIG. 4.55 – Extraits de l'ortho-image et des classifications et des confiances de classifications des synthèses 2018_P45 et 2018_P105 et 2018_P165 de séries d'images Sentinel-2_L3A avec la légende à 9 classes, de petites classes locales sur la zone d'intérêt T33PUL.

Le Tableau 4.29 montre globalement que les scores sont faibles en comparant par région des classifications des synthèses de périodes 105 jours et la VT. Cependant, cette dernière diffère moyennement de toutes les classifications des synthèses avec des valeurs plus élevées des scores de 0,31 à 0,76. Plus précisément, **les classifications des synthèses mai_P105, novembre_P105 et 2018_P105 sont les plus proches de la VT avec des valeurs respectives moins fortes de 0,59, 0,53 et 0,31. Par ailleurs, les classifications des synthèses mensuelles mars_P105, septembre_P105 et novembre_P105 se rapprochent en étant toutes les trois les plus éloignées des autres classifications de synthèses et la VT avec de fortes valeurs des scores de 0,16 à 0,76**, ce qui justifie les bonnes qualités des synthèses de séries d'images optiques Sentinel-2 qui sont préalablement débarrassées par fusion précoce des résidus de nuages encore présents dans les séries d'images optiques du fait de la saison pluvieuse du mois de septembre sur la zone Nord. Par contre, la classification du groupe de synthèses mensuelles (mars_P105, septembre_P105 et novembre_P105) est très peu proche de celle de la synthèse mensuelle juillet_P105 avec un score de 0,43. De plus, les classifications des trois paires de synthèses (novembre_P105 et 2018_P105); (septembre_P105 et novembre_P105) et (novembre_P105 et 2018_P105) se rapprochent de celles des trois synthèses mensuelles mars_P105; juillet_P105 et septembre_P105 avec de faibles scores de 0,2; 0,43 et 0,22 respectivement.

TAB. 4.27 – Coefficients Kappa (K) et F-Scores moyens (FS) obtenus après comparaison pixel à pixel des classifications des synthèses de période 105 jours et la VT avec 9 classes.

	mar._P105		mai_P105		juil._P105		sep._P105		nov._P105		2018_P105		VT	
<i>k = 9</i>														
L3A_P105	K	FS	K	FS	K	FS	K	FS	K	FS	K	FS	K	FS
mars_P105	1,0	100,0	0,2	35,3	0,2	24,9	0,3	39,3	0,3	42,9	0,4	45,8	0,1	4,6
mai_P105	0,2	35,3	1,0	100,0	0,2	24,9	0,3	36,5	0,2	36,5	0,2	33,7	0,1	6,1
juillet_P105	0,2	24,9	0,2	24,9	1,0	100,0	0,2	30,5	0,2	29,9	0,2	30,4	0,1	3,6
septembre_P105	0,3	39,3	0,3	36,5	0,2	30,5	1,0	100,0	0,5	56,7	0,4	47,7	0,1	5,3
novembre_P105	0,3	42,9	0,2	36,5	0,2	29,9	0,5	56,7	1,0	100,0	0,5	53,0	0,1	5,0
2018_P105	0,4	45,8	0,2	33,7	0,2	30,4	0,4	47,7	0,5	53,0	1,0	100,0	0,1	3,3
VT	0,1	4,5	0,1	6,1	0,2	3,6	0,2	5,3	0,1	5,0	0,1	3,3	1,0	100,0

TAB. 4.28 – Coefficients Kappa (K) et F-Scores moyens (FS) obtenus après comparaison pixel à pixel des classifications des synthèses de période 165 jours et la VT avec 9 classes.

	avr._P165		juil._P165		oct._P165		2018_P165		VT	
<i>k = 9</i>										
L3A_P165	K	FS	K	FS	K	FS	K	FS	K	FS
avril_P165	1,0	100,0	0,2	22,2	0,5	57,1	0,4	31,1	0,1	8,2
juillet_P165	0,2	22,2	1,0	100,0	0,2	22,7	0,3	44,2	0,1	6,4
octobre_P165	0,5	57,1	0,2	22,7	1,0	100,0	0,3	30,5	0,1	9,1
2018_P165	0,4	31,1	0,3	44,2	0,3	30,5	1,0	100,0	0,1	3,5
VT	0,1	8,2	0,1	6,4	0,1	9,1	0,1	3,5	1,0	100,0

k : nombre de classes. VT : vérité terrain.

Selon le Tableau 4.30, les scores sont globalement très faibles en comparant par région des classifications des synthèses de périodes 165 jours et la VT. Cependant, cette dernière diffère faiblement de toutes les classifications des synthèses avec des valeurs plus élevées des scores de 0,32 à 0,47. Plus précisément, **les classifications des synthèses avril_P165 et 2018_P165 sont les plus proches de la VT avec des valeurs respectives moins fortes de 0,35 et 0,32. Par ailleurs, les classifications des synthèses mensuelles avril_P165 et octobre_P165 se rapprochent en étant toutes les deux les plus éloignées des autres classifications de synthèses avec des valeurs peu faibles des scores de 0,2 à 0,36, démontrant les bonnes qualités de ces synthèses mensuelles par rapport aux autres synthèses de même période.**

4.7.1.6 Influence de la nomenclature et de la dimension temporelle des données sur les classifications supervisées de la zone d'intérêt T33PUL

La nomenclature (légende) des données de référence et la dimension temporelle des données satellitaires (mensuelles ou annuelle) sont susceptibles de modifier les performances de classification. Ainsi, l'impact des périodes sur les résultats de classification précédemment étudiés pour les trois légendes (Sections 4.7.1.1 et 4.7.1.1.1) est analysé dans cette section.

4.7.1.6.1 Influence de la nomenclature des données de référence sur les classifications supervisées de la zone d'intérêt T33PUL La nomenclature (légende) des données de référence peut modifier les performances de classification. Ainsi, la Section 4.7.1.1 montre qu'on obtient les résultats les plus forts des classifications de l'année complète 2018 et des synthèses 2018_P105 et 2018_P315 pour la légende à 5 classes puis 2018_P45 pour la légende à 9 classes et enfin 2018_P165 et 2018_P225 pour la légende à

<i>L3A_P105</i>	mar.	mai	juil.	sept.	nov.	2018	VT
mars	0.00	0.32	0.43	0.27	0.20	0.22	0.64
mai	0.32	0.00	0.38	0.34	0.34	0.23	0.59
juillet	0.43	0.38	0.00	0.43	0.43	0.39	0.72
septembre	0.27	0.34	0.43	0.00	0.22	0.25	0.76
novembre	0.20	0.34	0.43	0.22	0.00	0.16	0.53
2018	0.20	0.22	0.25	0.22	0.15	0.00	0.31
VT	0.64	0.59	0.72	0.76	0.53	0.31	0.00

TAB. 4.29 – Moyennes des distances entre les histogrammes issues des classifications des synthèses de période 105 jours et de la VT avec 9 classes.

<i>L3A_P165</i>	avr.	juil.	oct.	2018	VT
avril	0.00	0.30	0.20	0.25	0.35
juillet	0.30	0.00	0.33	0.26	0.47
octobre	0.20	0.33	0.00	0.27	0.36
2018	0.25	0.26	0.27	0.00	0.32
VT	0.35	0.47	0.36	0.32	0.00

TAB. 4.30 – Moyennes des distances entre les histogrammes issues des classifications des synthèses de période 165 jours et de la VT avec 9 classes.

12 classes si l'on considère les FS. Cependant, l'analyse des K révèle que les meilleurs résultats sont généralement obtenus des classifications de l'année complète 2018 et de la synthèse 2018_P315 pour la légende à 5 classes puis des synthèses 2018_P45 et 2018_P105 pour la légende à 9 classes et enfin 2018_P165 et 2018_P225 pour la légende à 12 classes. D'après la Section 4.7.1.1.1, les résultats les plus forts sont obtenus des classifications de la synthèse 2018_P45 pour les trois légendes si l'on considère les FS tandis que l'analyse de K démontre que le meilleur résultat est obtenu de la classification de la synthèse mensuelle septembre_P45 pour la légende à 5 classes. Bien que les résultats soient moins bons selon les K dans la classification de la synthèse 2018_P45 pour cette légende, les performances obtenus des classifications des synthèses mensuelles de périodes P45 sont toutefois moins meilleurs pour la légende à 5 classes.

4.7.1.6.2 Influence de la dimension temporelle des données satellitaires sur les classifications supervisées de la zone d'intérêt T33PUL La dimension temporelle des images satellitaires (mensuelles ou annuelle) peut également modifier les performances de classification. Ainsi, la Section 4.7.1.1 montre qu'on obtient les résultats les plus forts pour la légende à 5 classes, des classifications de l'année complète 2018 et des synthèses 2018_P105 et 2018_P315 puis pour la légende à 9 classes, de la

classification de la synthèse 2018_P45 et enfin pour la légende à 12 classes, des classifications des synthèses 2018_P165 et 2018_P225 si l'on considère les FS. De plus, l'analyse des K révèle que les meilleurs résultats sont généralement obtenus pour la légende à 5 classes, des classifications de l'année complète 2018 et de la synthèse 2018_P315 puis pour la légende à 9 classes, des classifications des synthèses 2018_P45 et 2018_P105 et enfin pour la légende à 12 classes, des classifications des synthèses 2018_P165 et 2018_P225. D'après la Section 4.7.1.1.1, les résultats les plus forts sont obtenus pour la légende à 5 classes, de la classification de la synthèse 2018_P45 si l'on considère les FS. Par contre, l'analyse de K démontre que les meilleurs résultats sont obtenus pour la légende à 5 classes, de la classification de la synthèse mensuelle septembre_P45. Bien que les résultats des classifications des synthèses mensuelles de périodes P45 soient moins bons, celle de la synthèse mensuelle septembre_P45 se rapprochent particulièrement du résultat de la classification de la synthèse 2018_P45 pour la légende à 5 classes.

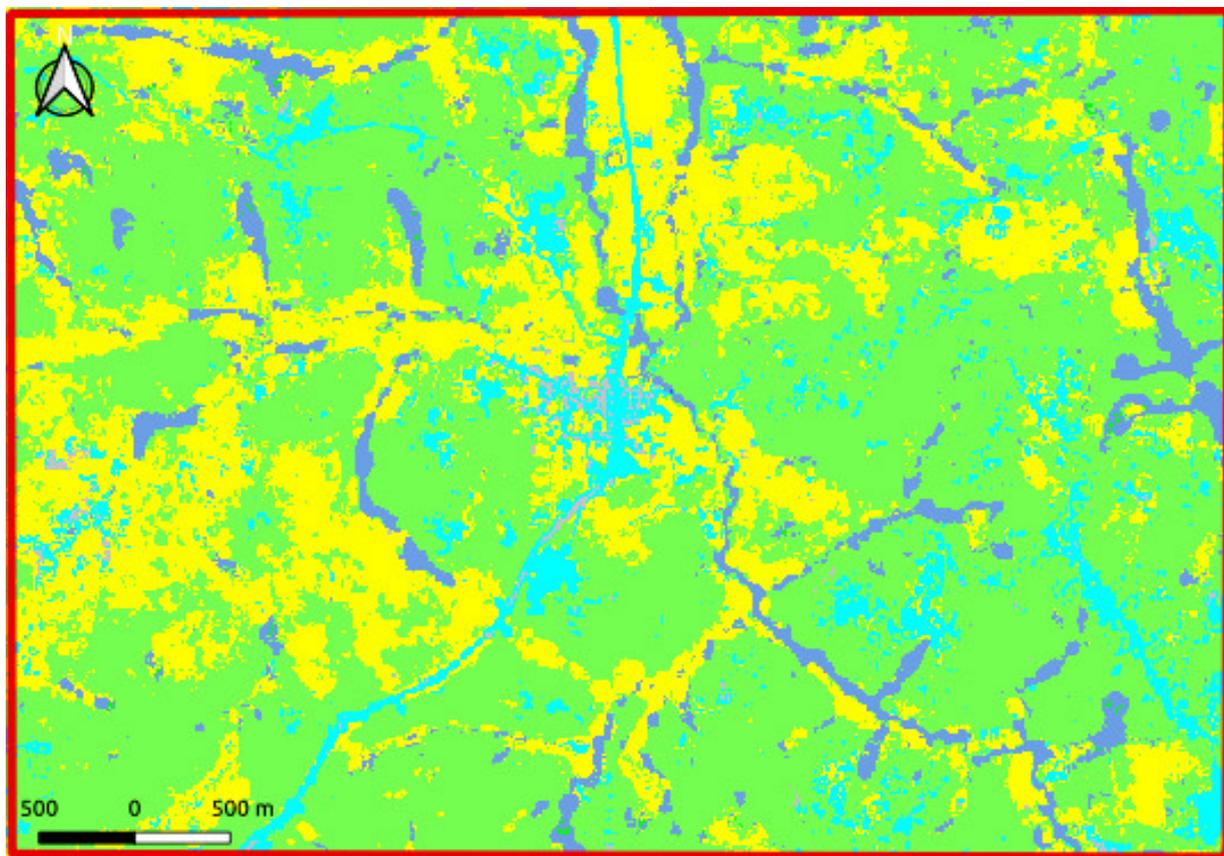
4.7.2 Zone d'intérêt T32NPL (ZONE2, Ouest-Centre)

Les extraits des classifications supervisées des fusions précoces de dix, cinq et trois synthèses mensuelles de période 45 jours (2018_P45), 105 jours (2018_P105) et 165 jours (2018_P165) pour la légende à 9 classes sont présentées dans les Figures 4.56A, 4.57A et 4.58A.

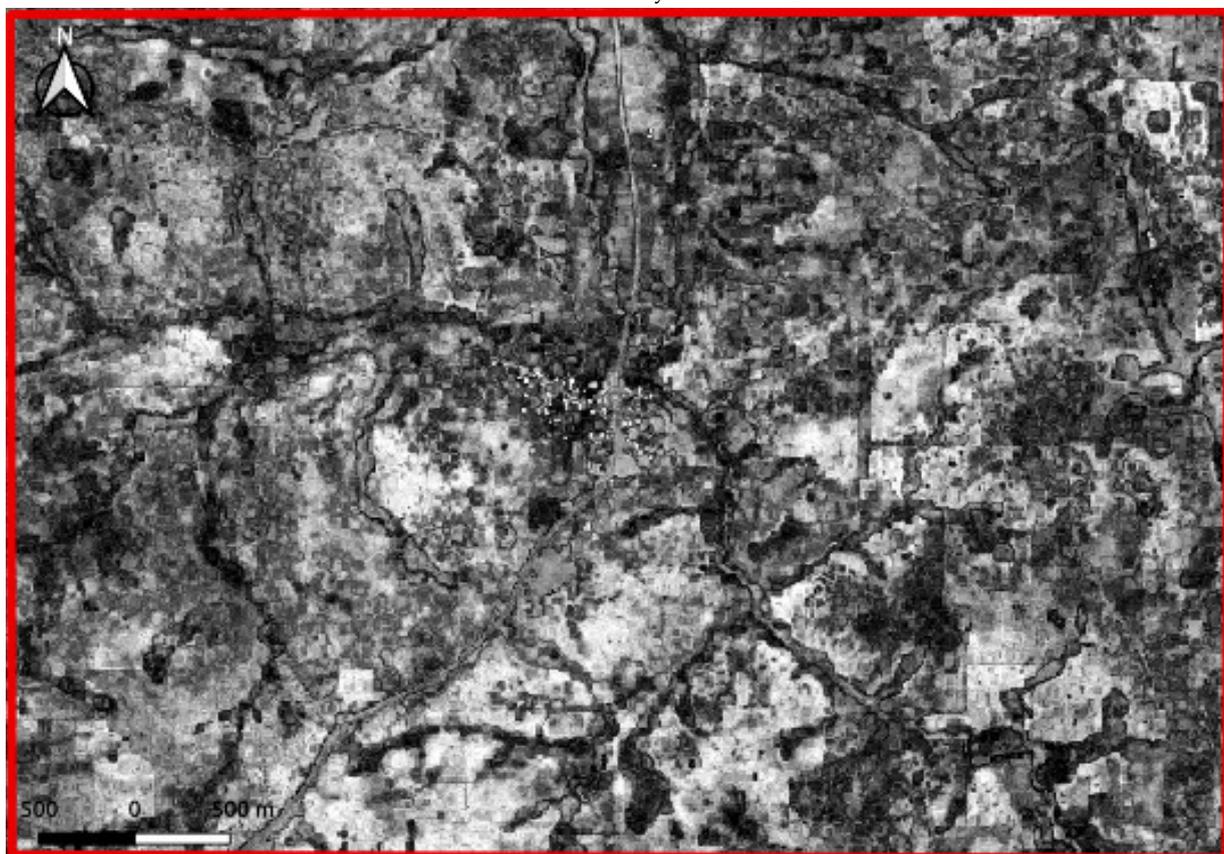
4.7.2.1 Evaluation quantitative des classifications supervisées de la zone d'intérêt T32NPL

Les Figures 4.59 et 4.60 présentent respectivement les métriques de qualité globale - F-Scores moyens (FS) et coefficients Kappa (K) des classifications supervisées de l'année complète 2018 et des synthèses 2018_P45, 2018_P105, 2018_P165, 2018_P225 et 2018_P315 de séries temporelles d'images optiques Sentinel-2_L3A pour les trois légendes. Quelle que soit la légende utilisée dans les classifications, les valeurs de FS et de K avec les images optiques sont globalement variables et faibles ($0,3 < FS < 0,33$ et $0,32 < K < 0,53$). Globalement, **les résultats les plus forts sont associés aux classifications de l'année complète 2018 pour les trois légendes si l'on considère les FS et pour la légende à 12 classes si l'on considère les K ainsi qu'aux classifications de la synthèse 2018_P45 pour les légendes à 5 et 9 classes si l'on considère les K. En considérant les classifications de synthèses seules, les résultats les plus forts sont associés aux classifications de la synthèse 2018_P45 pour les légendes à 5 et 9 classes et de la synthèse 2018_P105 pour la légende à 12 classes si l'on considère les FS et aux classifications de la synthèse 2018_P45 pour les trois légendes si l'on considère les K.** Au contraire, les résultats les plus faibles sont associés aux classifications des synthèses 2018_P315 pour les légendes à 5 et 12 classes et 2018_P225 pour la légende à 9 classes à la fois du point de vue des FS et des K. Ces résultats montrent de meilleures performances de classification de la synthèse 2018_P45 pour les légendes à 5 et 9 classes. D'où l'importance de la fusion précoce (génération de synthèses et *gapfilling* dans *iota*²) des séries et synthèses de séries temporelles d'images optiques dans la cartographie des classes d'OCS.

Les Figures 4.61, 4.62 et 4.63 présentent les métriques de qualité par classe - F-Score (FS/classe), précision utilisateur (PU) et précision producteur (PP) des classifications supervisées des synthèses de synthèses mensuelles de séries temporelles d'images optiques Sentinel-2_L3A pour les légendes à 5, 9 et 12 classes respectivement. L'utilisation des légendes à 5 et 9 classes permet d'améliorer les classifications de l'année complète 2018 des classes EAU (FS (EAU) $\simeq 0,8$); RTE (FS (RTE) $\simeq 0,17$) et BTM (FS (BTM) $\simeq 0,56$) et des synthèses 2018_P45 de la classe VGT (FS (VGT) $\simeq 0,88$) et 2018_P105 de la classe AGR (FS (AGR) $\simeq 0,59$) pour la légende à 5 classes et les classifications de l'année complète 2018 des classes AGR (FS (AGR) $\simeq 0,59$); SFE (FS (SFE) $\simeq 0,02$); ZHU (FS (ZHU) $\simeq 0,07$) et BTM (FS

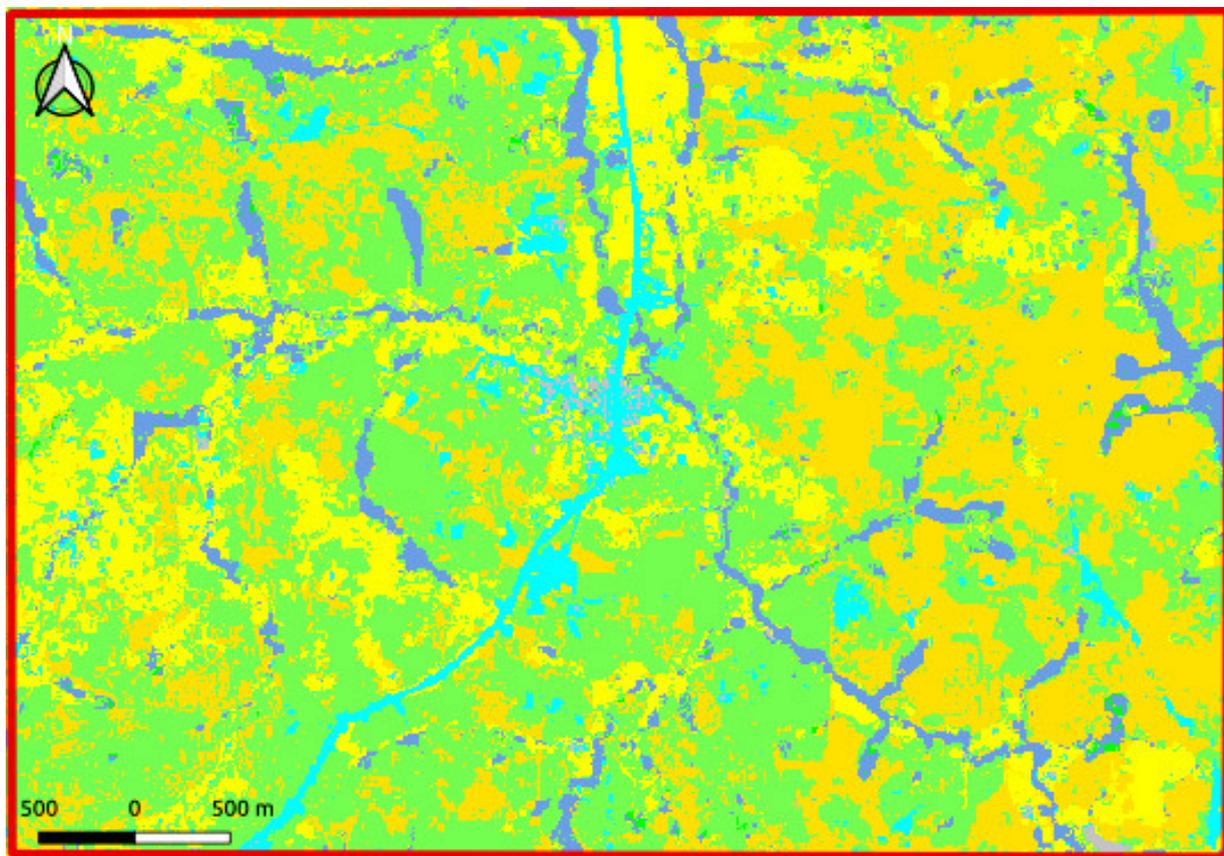


(A) Classification de la synthèse 2018_P45

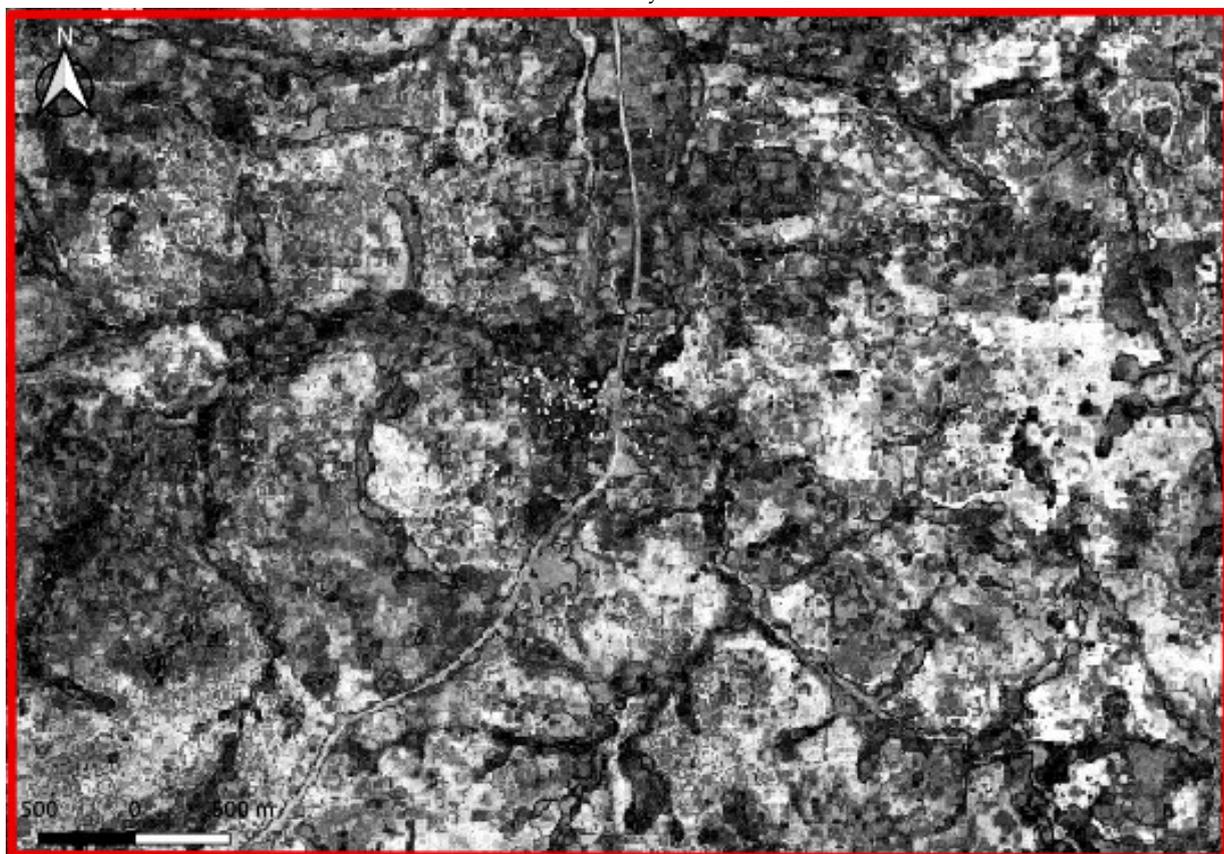


(B) Confiance de la classification de la synthèse 2018_P45

FIG. 4.56 – Extraits de la classification supervisée de la synthèse 2018_P45 de séries temporelles d'images optiques Sentinel-2_L3A avec la légende à 9 classes : ■ : FRT ; ■ : PRA ; ■ : ARB ; ■ : AGR ; ■ : SFE ; ■ : ZHU ; ■ : RIV ; ■ : RTE ; ■ : BTM et de la confiance : ■ : faibles → ■ : fortes valeurs, de la zone d'intérêt T32NPL.

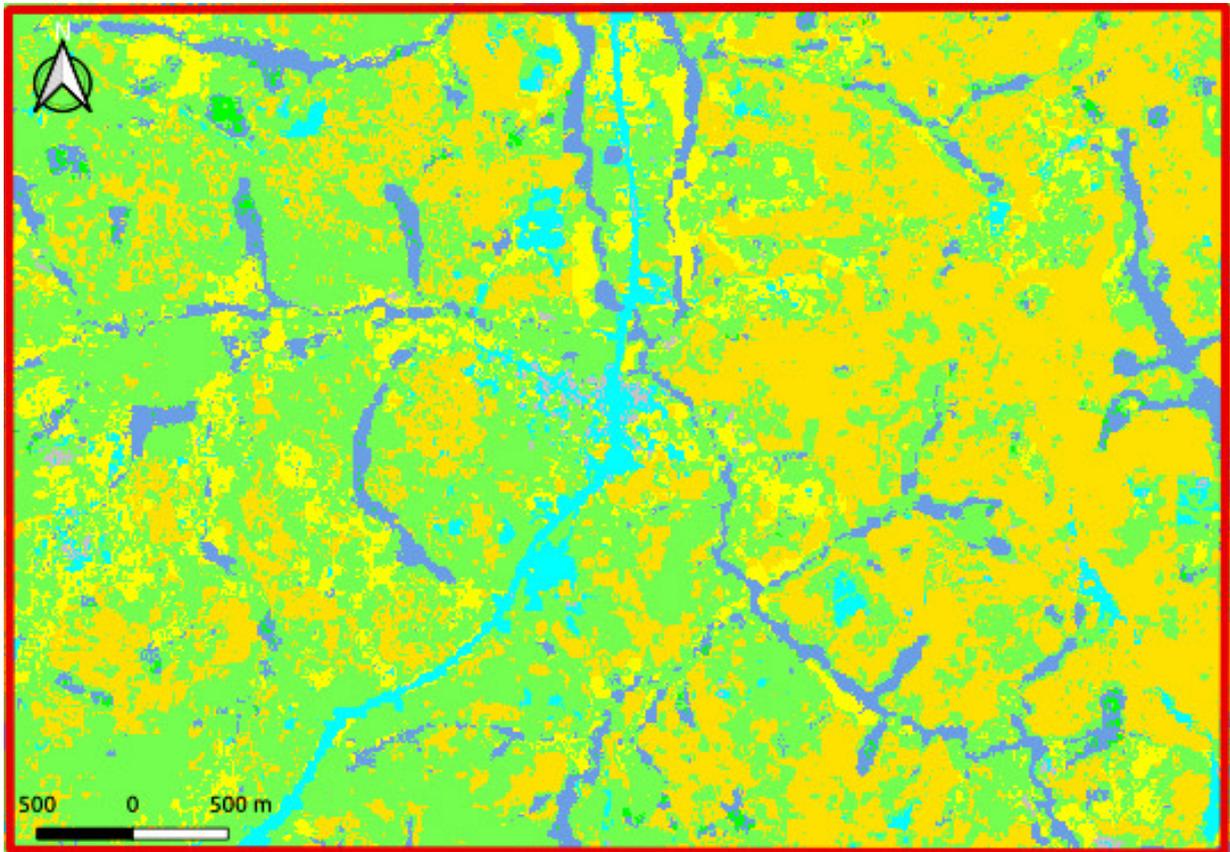


(A) Classification de la synthèse 2018_P105

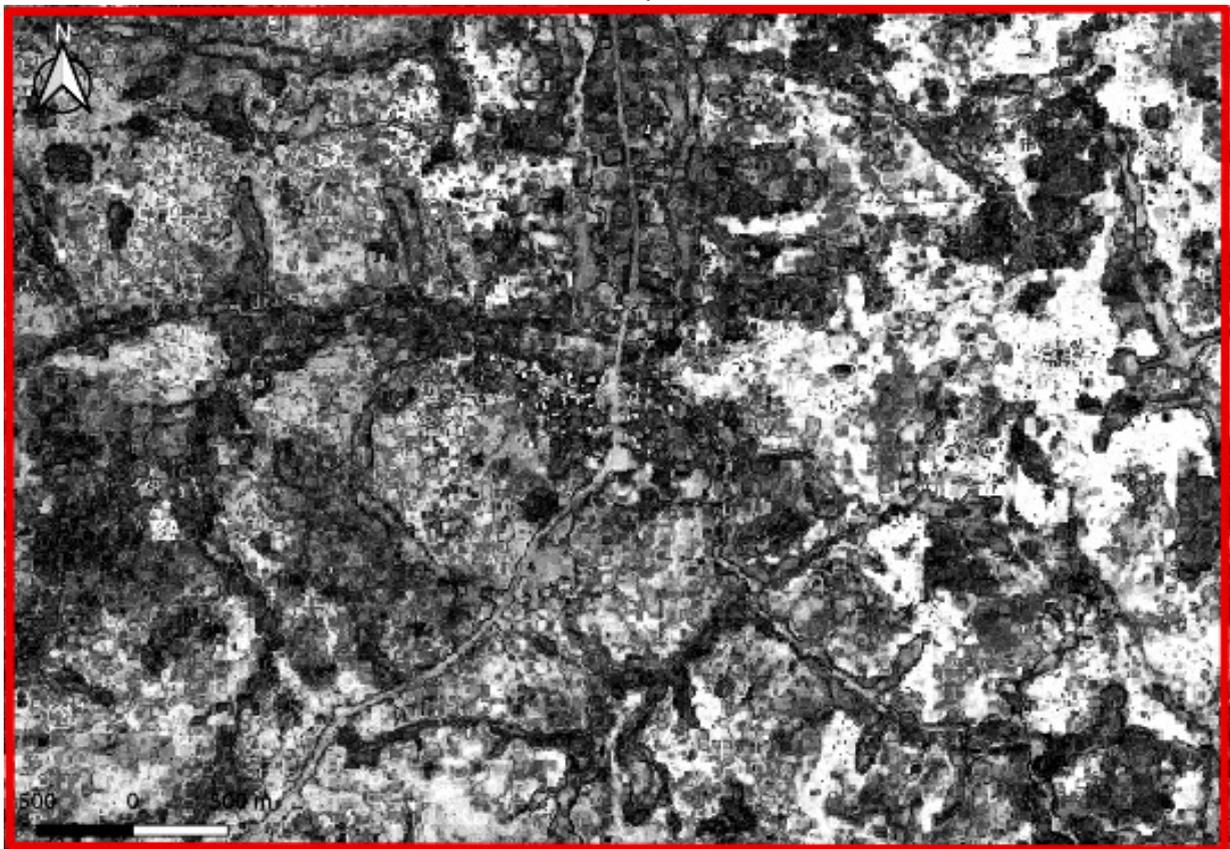


(B) Confiance de la classification de la synthèse 2018_P105

FIG. 4.57 – Extraits de la classification supervisée de la synthèse 2018_P105 de séries temporelles d'images optiques Sentinel-2_L3A avec la légende à 9 classes : ■ : FRT ; ■ : PRA ; ■ : ARB ; ■ : AGR ; ■ : SFE ; ■ : ZHU ; ■ : RIV ; ■ : RTE ; ■ : BTM et de la confiance : ■ : faibles → ■ : fortes valeurs, de la zone d'intérêt T32NPL.



(A) Classification de la synthèse 2018_P165



(B) Confiance de la classification de la synthèse 2018_P165

FIG. 4.58 – Extraits de la classification supervisée de la synthèse 2018_P165 de séries temporelles d'images optiques Sentinel-2_L3A avec la légende à 9 classes : ■ : FRT; ■ : PRA; ■ : ARB; ■ : AGR; ■ : SFE; ■ : ZHU; ■ : RIV; ■ : RTE; ■ : BTM et de la confiance : ■ : faibles → ■ : fortes valeurs, de la zone d'intérêt T32NPL.

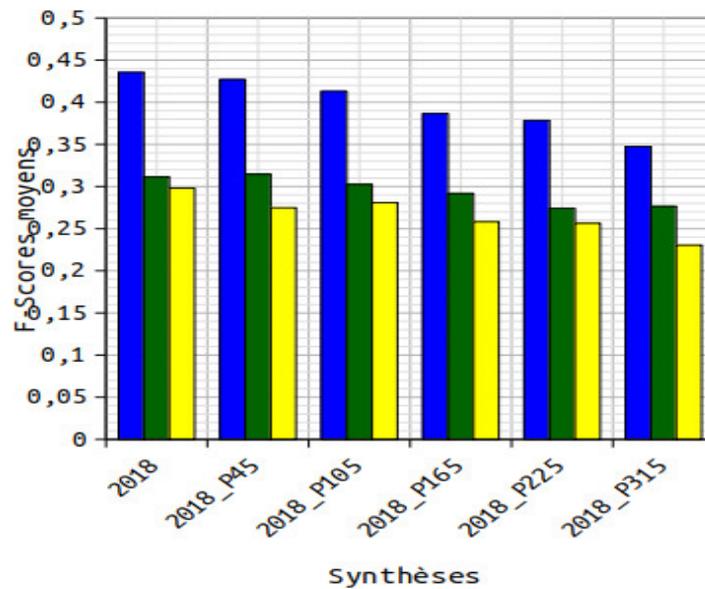


FIG. 4.59 – F-Scores moyens des classifications supervisées des différentes synthèses de séries temporelles d’images optiques Sentinel-2_L3A avec les légendes à 5 et 9 et 12 classes, de la zone d’intérêt T32NPL.

(BTM) $\simeq 0,51$) et des synthèses 2018_P45 des classes PRA (FS (PRA) $\simeq 0,04$) et RIV (FS (RIV) $\simeq 0,08$) et 2018_P105 de la classe ARB (FS (ARB) $\simeq 0,07$) et 2018_P165 de la classe FRT (FS (FRT) $\simeq 0,91$) et 2018_P225 de la classe RTE (FS (RTE) $\simeq 0,22$) pour la légende à 9 classes. L’utilisation de la légende à 12 classes permet également d’améliorer les classifications des synthèses 2018_P45 des classes VHB (FS (VHB) $\simeq 0,41$); FOU (FS (FOU) $\simeq 0,42$); TCU (FS (TCU) $\simeq 0,35$); ARB (FS (ARB) $\simeq 0,4$) et BTM (FS (BTM) $\simeq 0,49$) et 2018_P105 des classes SFE (FS (SFE) $\simeq 0,02$); ZHU (FS (ZHU) $\simeq 0,04$); RTE (FS (RTE) $\simeq 0,27$); FFE (FS (FFE) $\simeq 0,59$); ZHH (FS (ZHH) $\simeq 0,25$); FFE (FS (FFE) $\simeq 0,59$) et RIV (FS (RIV) $\simeq 0,2$). **Les meilleurs résultats sont alors obtenus pour la légende à 9 classes, où le FS/classe atteint le FS (FRT) $\simeq 0,91$ de la classe FRT dans la classification de la synthèse 2018_P165 et les précisions PU et PP y atteignent respectivement la PU (FRT) $\simeq 0,96$ et la PP (FRT) $\simeq 0,86$ de la classe FRT.**

La fusion des *BDs* améliore les résultats d’un plus grand nombre de classes comme c’est le cas dans les classifications des synthèses 2018_P45 et 2018_P105 pour la légende à 12 classes. Par contre, ces performances sont de moins bonne qualité dans la classification de la synthèse 2018_P105 pour cette légende. Ce résultat montre que l’ajout de *BDs* n’améliore pas la performance de classification d’une plus grande période de synthèse. Par conséquent, il serait plus judicieux de prendre de petites périodes de synthèse mensuelle de séries temporelles d’images optiques dans la classification d’un nombre élevé de classes d’OCS.

La fusion précoce de multiples de séries temporelles d’images optiques ainsi que la fusion des classes FRT; PRA et ARB dans la légende à 9 classes en une *BDs* compacte renfermant la classe VGT de la légende à 5 classes offrent également de bons résultats. En effet, l’utilisation de la classe VGT augmente grandement les performances de la classification annuelle (FS = 0,33; PU (VGT) $\simeq 0,96$) pour la légende à 5 classes, alors que le FS de la classification de la synthèse 2018_P45 est de 0,32 lorsque les classes FRT; PRA et ARB sont considérées indépendamment (PU (FRT) $\simeq 0,96$; PU (PRA) $\simeq 0,04$ et PU (ARB) $\simeq 0,48$) pour la légende à 9 classes. Les valeurs de FS et de PU restent cependant de bonne qualité comparativement à la classification de la synthèse 2018_P45 pour la légende à 12

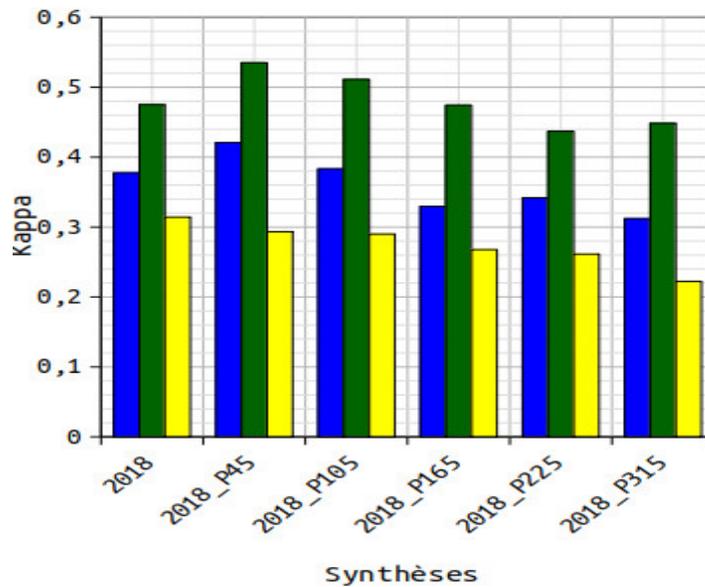


FIG. 4.60 – Coefficients Kappa des mêmes classifications que les FS dans la Figure 4.59.

classes. **La fusion des classes FRT ; PRA et ARB est pertinente ici, dans la classification de la fusion précoce d'un nombre élevé de séries temporelles d'images optiques, comme en atteste la forte valeur de FS de la classification annuelle pour la légende à 5 classes.** Dans ce cas, la fusion des classes d'OCS apporte de nouvelles étiquettes nécessaires dans la classification utilisant la fusion précoce d'un nombre élevé de séries temporelles d'images optiques Sentinel-2.

Les faibles performances de la paire de classes (SFE et ZHU) dans les classifications annuelle et de synthèses pour les légendes à 9 et 12 classes proviennent des réflectances des différentes classes. En effet, **les éléments agro-naturels issus de chacune des deux classes, peuvent avoir des réflectances très proches avec les images optiques durant les périodes de classification compliquant ainsi les classifications et rendant également difficile l'obtention préalable du contour d'un parcellaire.** De différentes classes d'OCS contiguës peuvent être regroupées dans une seule classe et une classe hétérogène peut correspondre à plusieurs autres classes d'OCS. Ces limites liées à la réalisation de classifications pour des données qui ne sont vraiment pas de référence peuvent donc impacter les résultats globaux mais également les confusions.

4.7.2.1.1 Cas particulier de classifications supervisées de synthèses de période P45 sur la zone d'intérêt T32NPL Les Figures 4.64 et 4.65 présentent respectivement les métriques de qualité globale - F-Scores moyens (FS) et coefficients Kappa (K) des classifications supervisées de synthèses de période P45 de séries temporelles d'images optiques Sentinel-2_L3A pour les trois légendes. Quelle que soit la légende utilisée dans les classifications, les valeurs de FS et de K avec les synthèses de périodes P45 sont variables et faibles ($0,16 < FS < 0,43$ et $0,08 < K < 0,53$). **Les résultats les plus forts sont associés aux classifications de la synthèse 2018_P45 pour les trois légendes à la fois du point de vue des FS et des K.** Au contraire, les résultats les plus faibles sont associés aux classifications des synthèses août_P45 pour les légendes à 5 et 9 classes à la fois du point de vue des FS et des K et septembre_P45 pour la légende à 12 classes si l'on considère les FS et octobre_P45 pour la légende à 12 classes si l'on considère les K. Ces résultats montrent que les trois légendes donnent de bonnes performances à la classification produite avec la synthèse 2018_P45. De plus, les classifications des synthèses août_P45

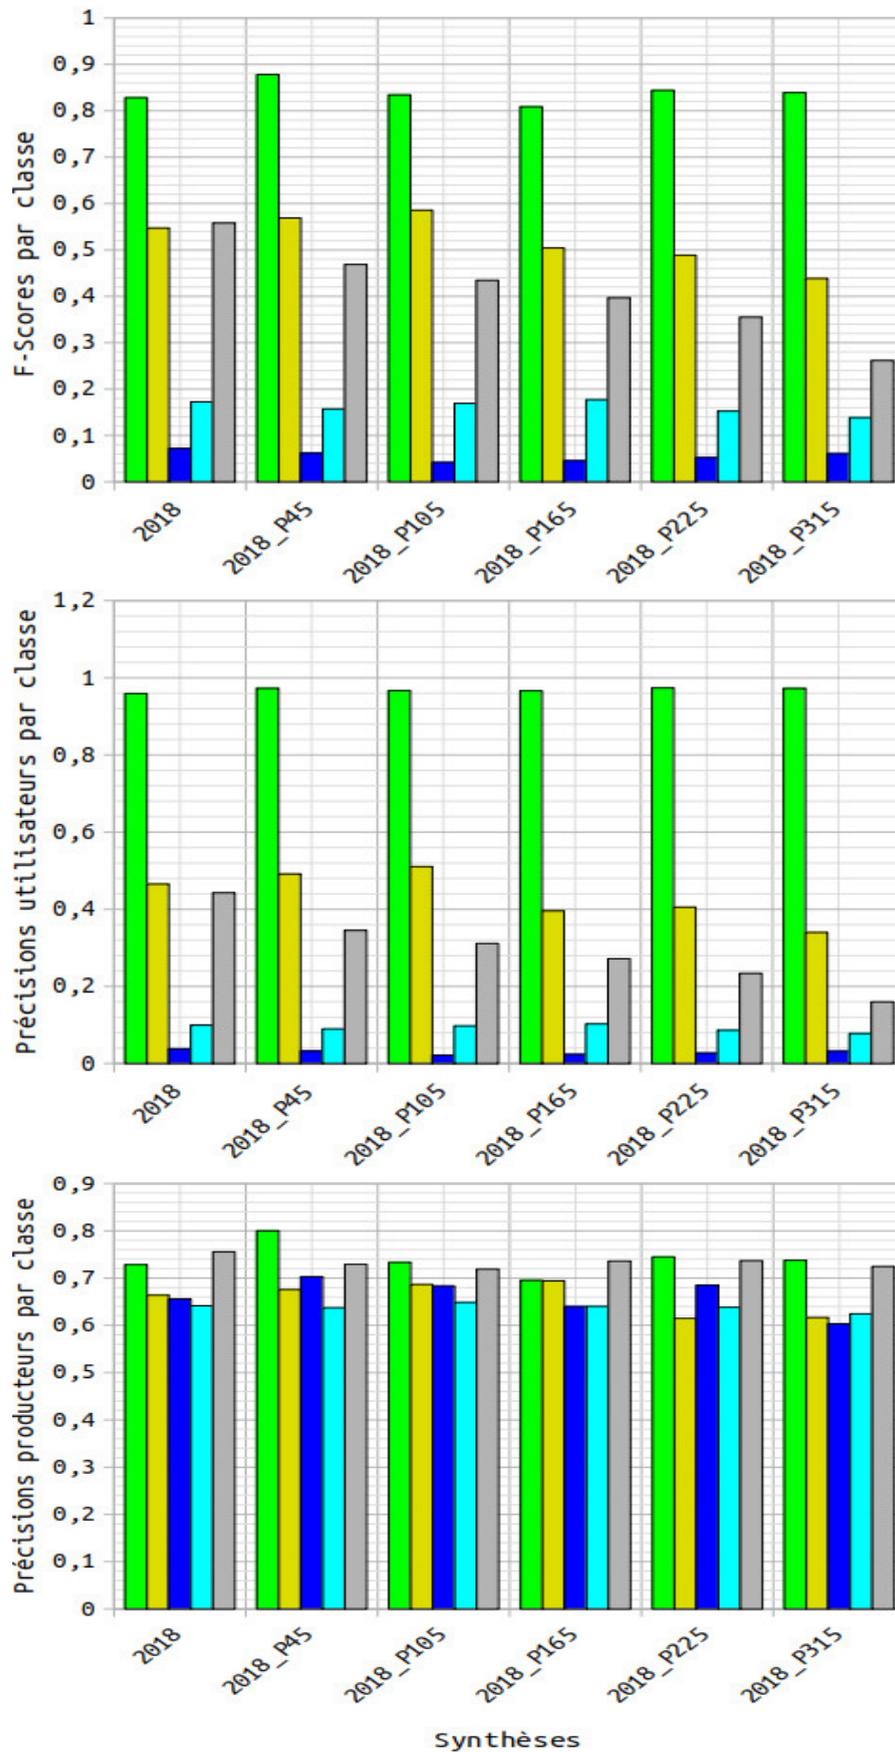


FIG. 4.61 – F-Scores et précision utilisateur et précision producteur par classe des classifications supervisées des synthèses de séries temporelles d’images optiques Sentinel-2_L3A avec la légende à 5 classes : ■ : VGT; ■ : AGR; ■ : EAU; ■ : RTE; ■ : BTM, de la zone d’intérêt T32NPL.

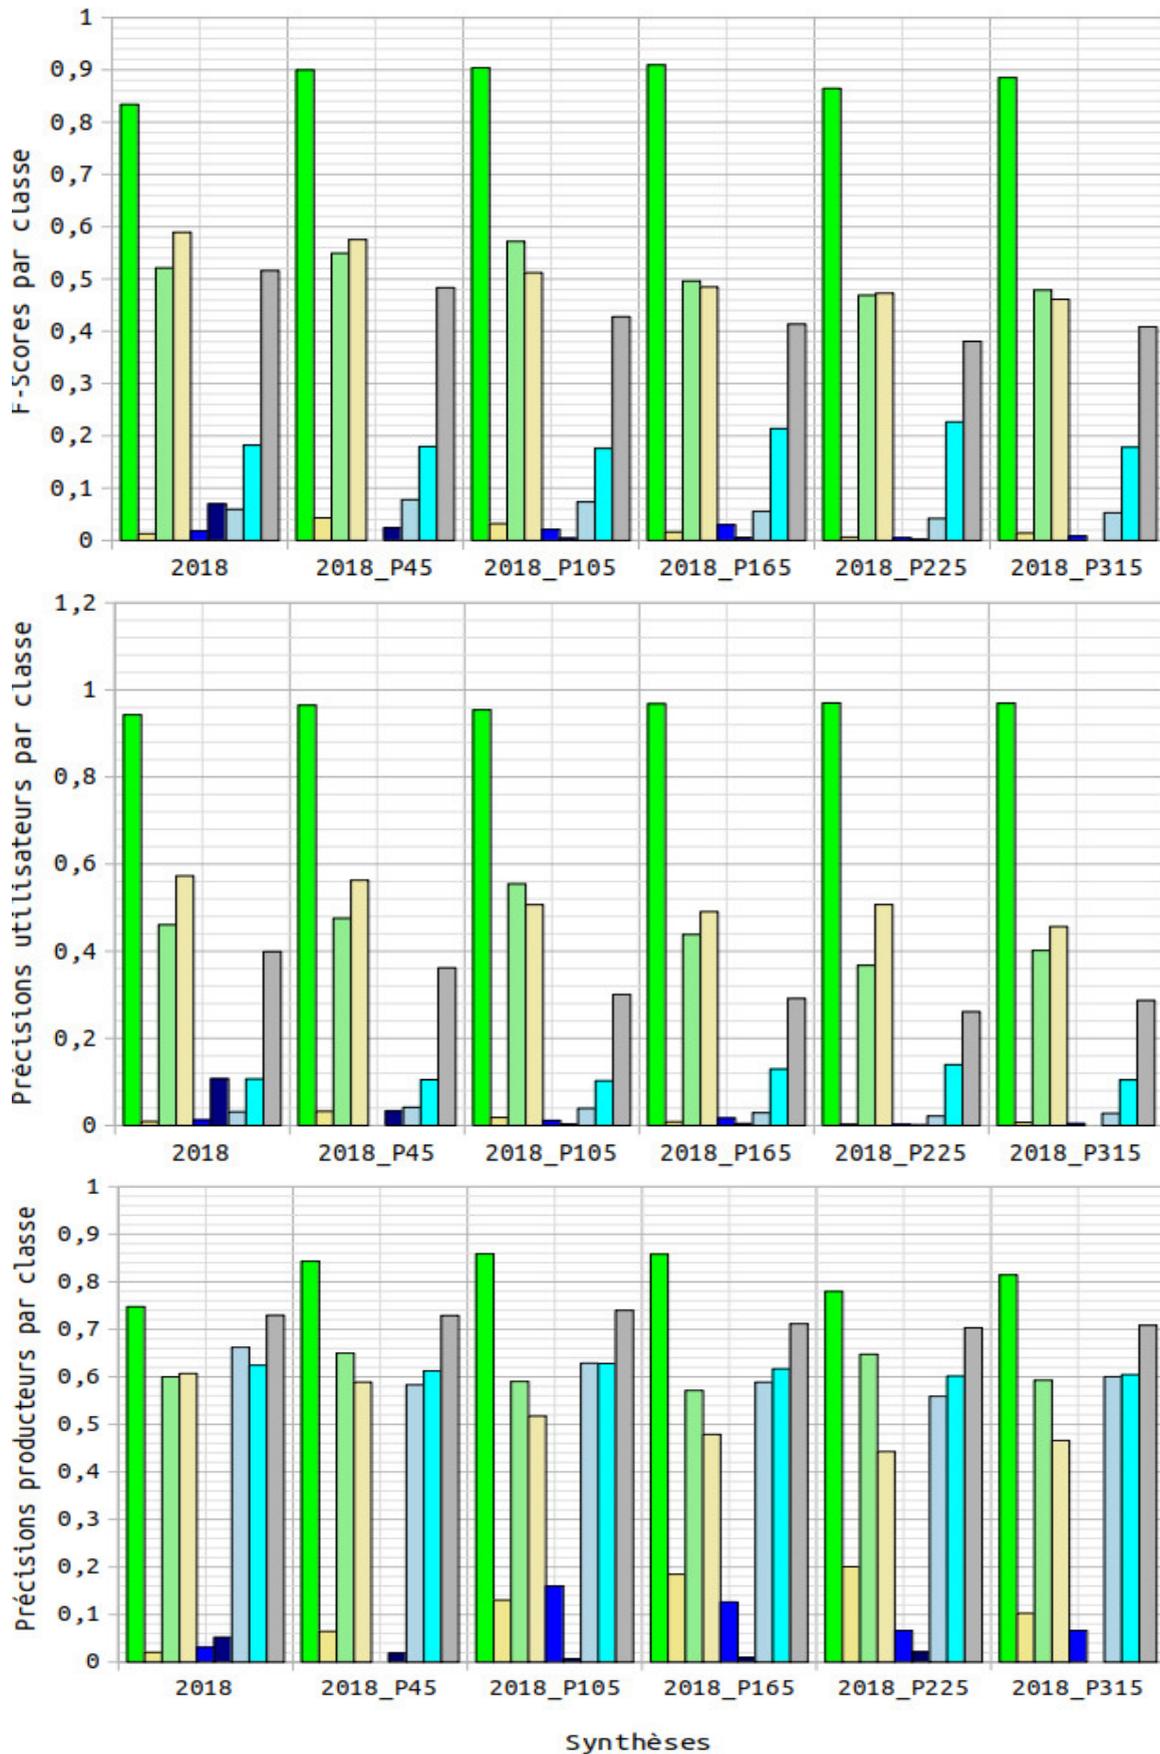


FIG. 4.62 – F-Scores et précision utilisateur et précision producteur par classe des classifications supervisées des synthèses de séries temporelles d’images optiques Sentinel-2_L3A avec la légende à 9 classes : ■ : FRT ; ■ : PRA ; ■ : ARB ; ■ : AGR ; ■ : SFE ; ■ : ZHU ; ■ : RIV ; ■ : RTE ; ■ : BTM, de la zone d’intérêt T32NPL.

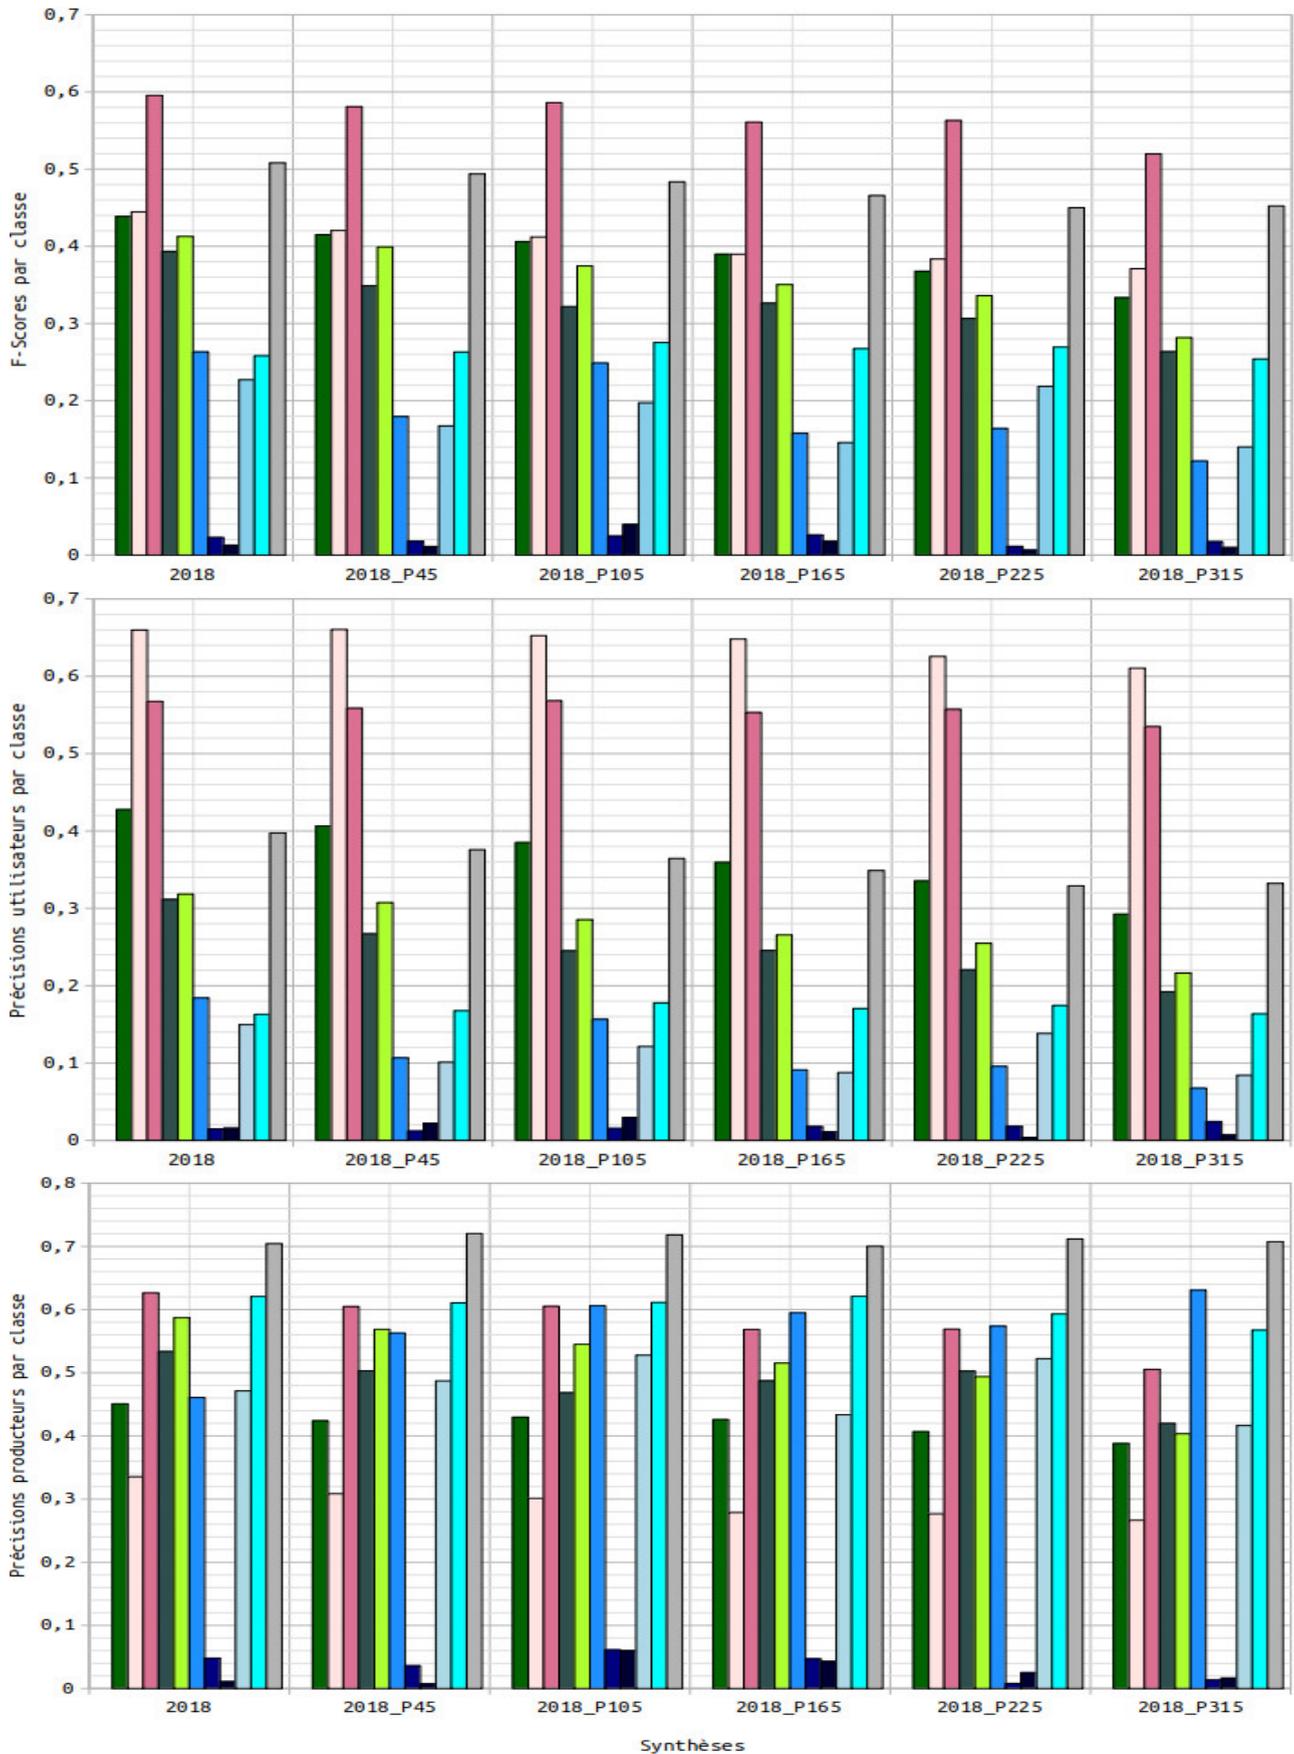


FIG. 4.63 – F-Scores et précision utilisateur et précision producteur par classe des classifications supervisées des synthèses de séries temporelles d’images optiques Sentinel-2_L3A avec la légende à 12 classes : ■ : VNC; ■ : VHB; ■ : FOU; ■ : FFE; ■ : TCU; ■ : ARB; ■ : ZHH; ■ : SFE; ■ : ZHU; ■ : RIV; ■ : RTE; ■ : BTM, de la zone d’intérêt T32NPL.

présentent de faibles résultats pour les légendes à 5 et 9 classes et septembre_P45 présente un faible résultat pour la légende à 12 classes. Ainsi, la synthèse 2018_P45 discrimine mieux les classes d'OCS constitutives des trois légendes que n'importe quelle synthèse mensuelle de période P45.

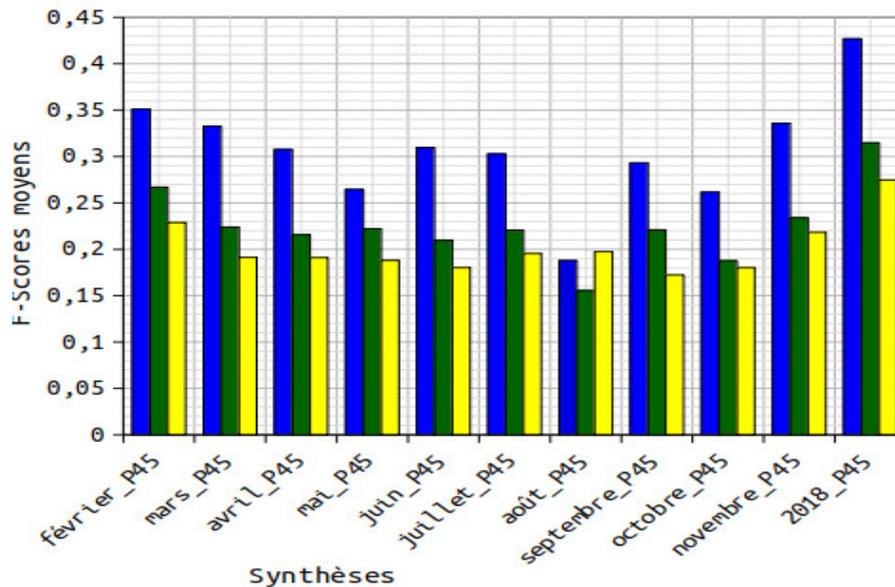


FIG. 4.64 – F-Scores moyens des classifications supervisées des synthèses de période P45 de séries temporelles d'images optiques Sentinel-2_L3A avec les légendes à 5 : ■ : OSM et 9 : ■ : OSM+INC et 12 : ■ : OSM+INC+GLC classes, de la zone d'intérêt T32NPL.

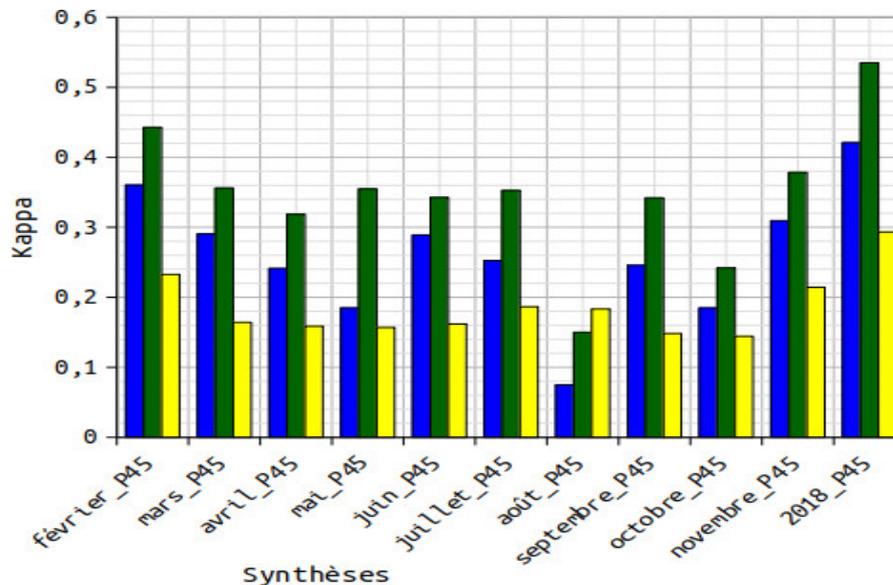


FIG. 4.65 – Coefficients Kappa des mêmes classifications que les FS dans la Figure 4.64.

Les Figures 4.66, 4.67 et 4.68 présentent les métriques de qualité par classe - F-Score (FS/classe), précision utilisateur (PU) et précision producteur (PP) des classifications supervisées des synthèses de période P45 de séries temporelles d'images optiques Sentinel-2_L3A pour les légendes à 5, 9 et 12 classes respectivement. L'utilisation des légendes à 5 et 9 classes permet d'améliorer les classifications de la synthèse 2018_P45 de toutes les classes EAU (FS (EAU) $\simeq 0,08$); RTE (FS (RTE) $\simeq 0,18$); BTM (FS (BTM) $\simeq 0,48$); AGR (FS (AGR) $\simeq 0,58$) et VGT (FS (VGT) $\simeq 0,88$) pour la légende à 5 classes puis

des classes FRT (FS (FRT) $\simeq 0,9$); ARB (FS (ARB) $\simeq 0,54$) et AGR (FS (AGR) $\simeq 0,58$) pour la légende à 9 classes. De plus, la classe FRT est mieux détectée en début d'année dans les classifications des synthèses février_P45 et mars_P45 (FS (FRT) $\simeq 0,79$) et vers la fin de l'année dans les classifications des synthèses septembre_P45 et novembre_P45 (FS (FRT) $\simeq 0,72$) pour la légende à 9 classes. L'utilisation de la légende à 12 classes permet également d'améliorer les classifications de la synthèse 2018_P45 de toutes les classes. **Les meilleurs résultats sont alors obtenus pour la légende à 9 classes, où le FS/classe atteint le FS (FRT) $\simeq 0,9$ de la classe FRT dans la classification de la synthèse 2018_P45 et les précisions PU et PP atteignent respectivement la PU (FRT) $\simeq 0,96$ et la PP (FRT) $\simeq 0,84$ de la classe FRT qui y est par ailleurs sur-détectée.**

La fusion des BDs d'OSM, de l'INC et de GLC (OSM+INC+GLC) constituant la légende à 12 classes, offre également de bonnes performances aux classifications des synthèses de période P45 mais qui sont de moins bonne qualité avec la plupart des synthèses mensuelles comparativement à celles correspondant aux légendes à 5 et 9 classes. Néanmoins, la légende à 12 classes permet l'amélioration des résultats des onze classes dans la classification de la synthèse 2018_P45. Ce résultat montre que l'ajout de BDs diminue les performances de classification des synthèses mensuelles. C'est ainsi que **la classe SFE n'est pas détectée dans les classifications des synthèses mensuelles mars_P45, mai_P45 et octobre_P45 de même que la classe ZHU ne l'est non plus dans les classifications des synthèses mensuelles avril_P45, mai_P45, juillet_P45, août_P45 et septembre_P45 pour la légende à 9 classes et que la classe VNC n'est détectée dans aucune des classifications pour la légende à 12 classes.** Par conséquent, il est plus judicieux d'effectuer préalablement la fusion précoce des différentes synthèses mensuelles de période P45 de séries temporelles d'images optiques pour la classification d'un nombre élevé de classes d'OCS.

La fusion des classes FRT; PRA et ARB dans la légende à 9 classes en classe VGT de la légende à 5 classes augmente les performances de classification de la synthèse 2018_P45 (FS = 0,43; PU (VGT) $\simeq 0,97$) pour la légende à 5 classes, alors que le FS de la classification de la synthèse août_P45 est de 0,16 lorsque les classes FRT; PRA et ARB sont considérées indépendamment (PU (FRT) $\simeq 0,89$; PU (PRA) $\simeq 0,01$ et PU (ARB) $\simeq 0,41$) pour la légende à 9 classes. Cependant, les valeurs de FS et de PU des classes restent de bonne qualité dans la classification de la synthèse août_P45 par rapport à celles pour la légende à 12 classes. **La fusion des classes FRT; PRA et ARB est donc pertinente pour améliorer les classifications de synthèses de période P45, comme démontrées par les fortes valeurs de FS des classes au sein de ces classifications pour la légende à 5 classes.** Dans ce cas, la fusion des classes d'OCS améliore les résultats des classifications de synthèses de périodes P45 de séries temporelles d'images optiques Sentinel-2.

Les faibles performances de la paire de classes (SFE et ZHU) dans les classifications des synthèses mensuelles de périodes P45 pour les légendes à 9 et 12 classes proviennent entre autres des réflectances des différentes classes. En effet, **les éléments naturels provenant des classes en question, peuvent avoir des réflectances très proches en présence de synthèses d'images optiques durant cette période de synthèse du fait des résidus de nuages, d'aérosols etc. encore présents dans ces synthèses, compliquant ainsi les classifications en vue d'une meilleure discrimination et rendant difficile l'obtention préalable de données de référence fiables.** De différentes classes d'OCS contiguës peuvent être regroupées dans une seule classe et une classe hétérogène peut correspondre à plusieurs autres classes d'OCS. Ces limites liées à la réalisation de classifications basées sur des données qui ne sont vraiment pas de référence peuvent donc impacter les résultats globaux mais également les confusions.

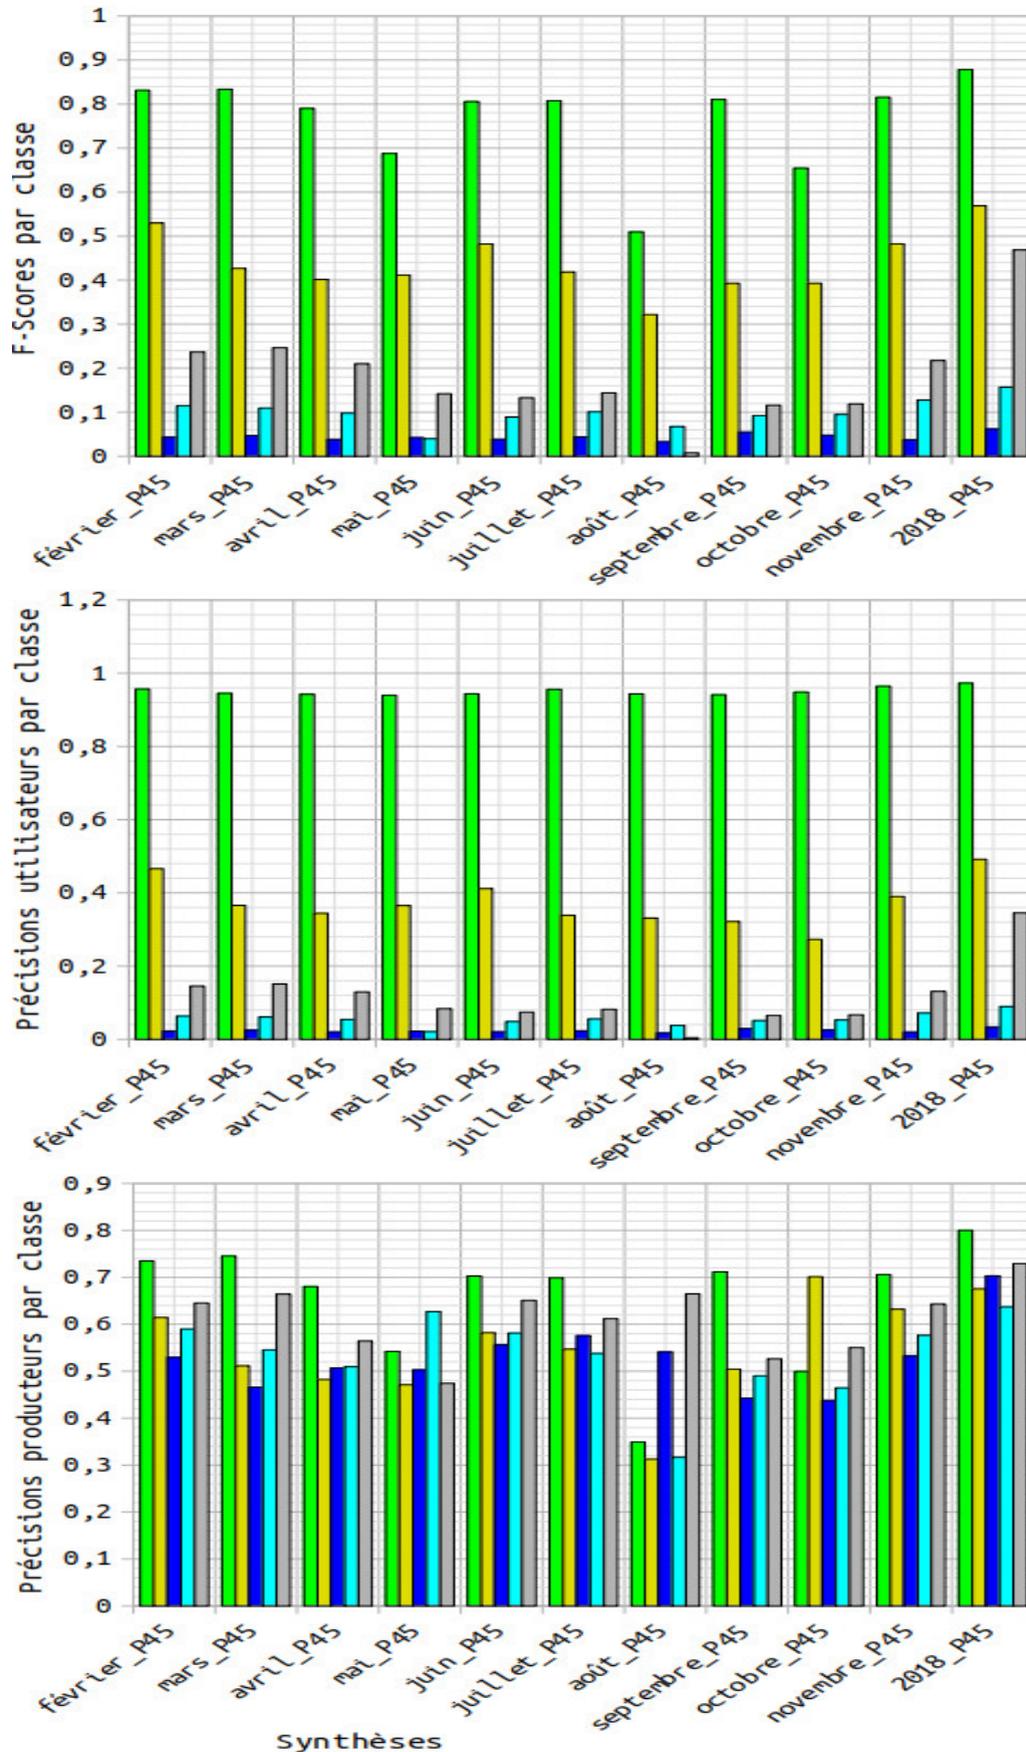


FIG. 4.66 – F-Scores et précision utilisateur et précision producteur par classe des classifications supervisées des synthèses de période *P45* de séries temporelles d'images optiques Sentinel-2_L3A avec la légende à 5 classes : ■ : VGT; ■ : AGR; ■ : EAU; ■ : RTE; ■ : BTM, de la zone d'intérêt T32NPL.

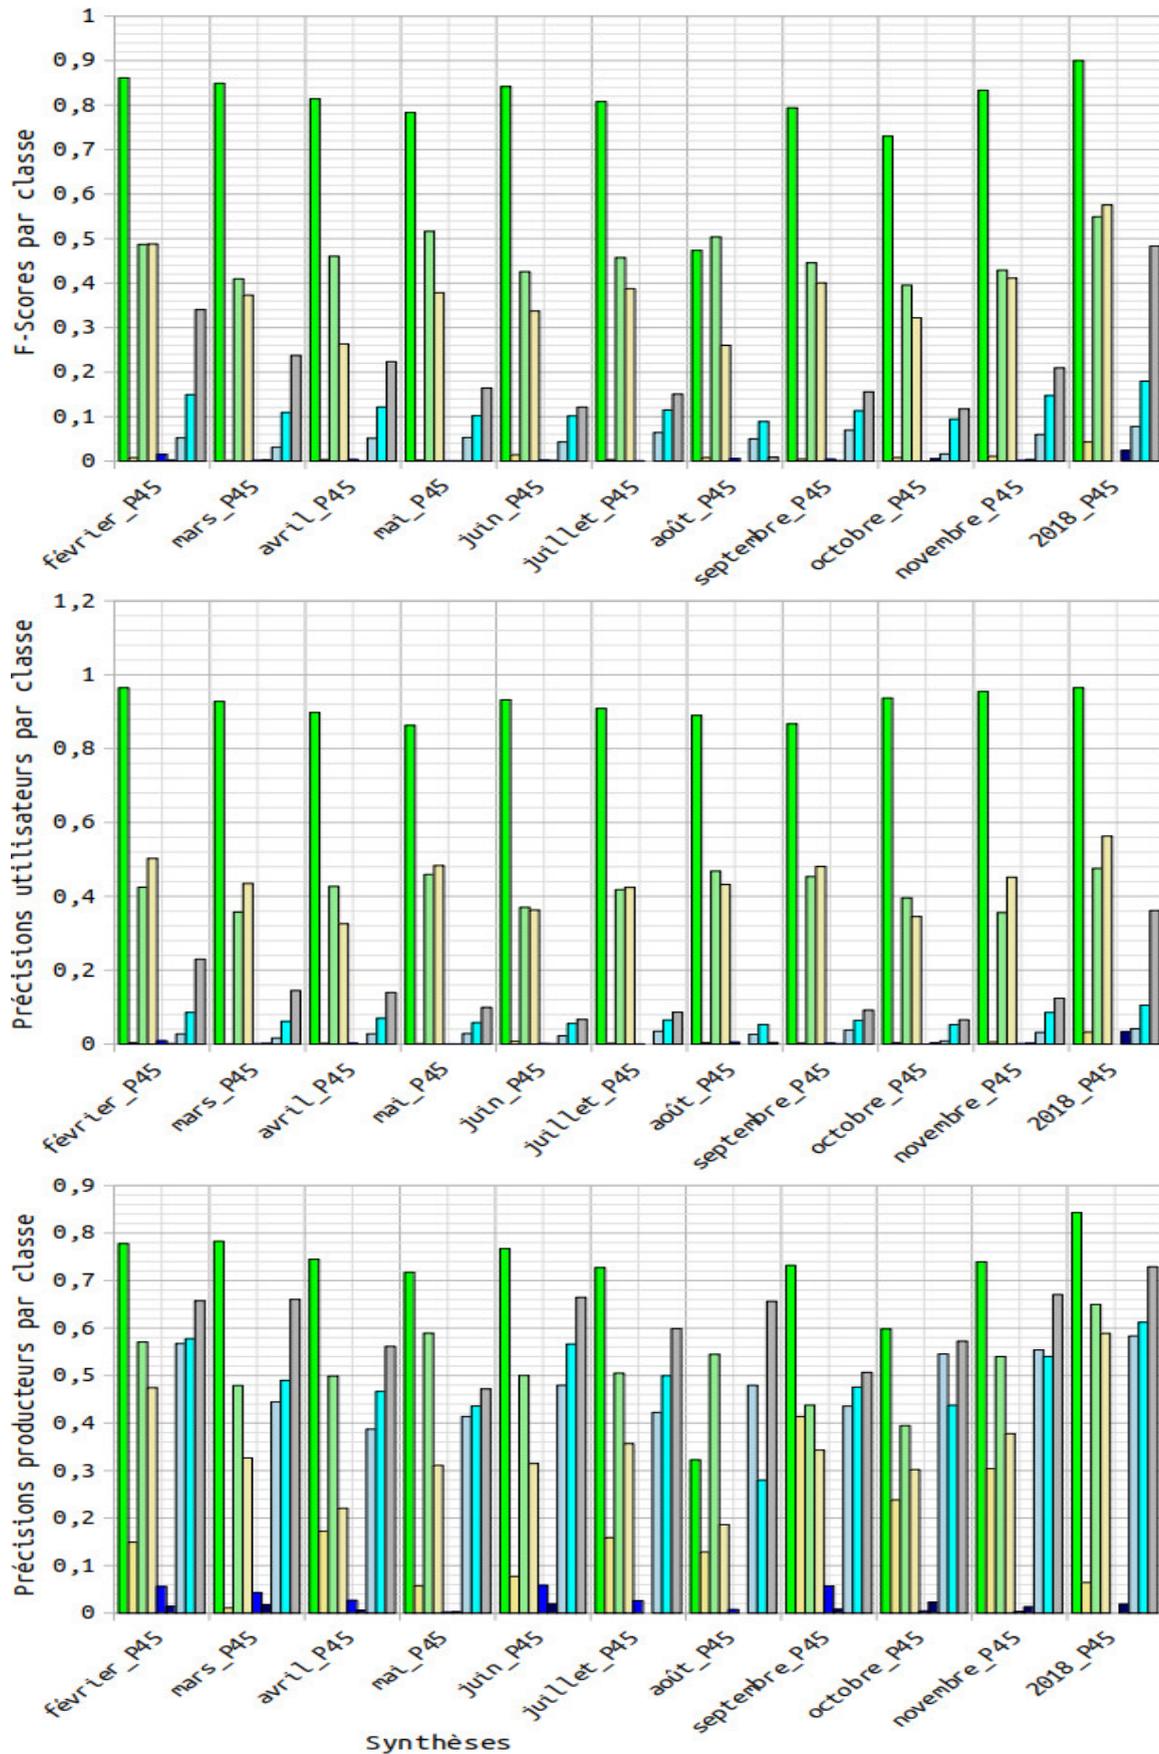


FIG. 4.67 – F-Scores et précision utilisateur et précision producteur par classe des classifications supervisées des synthèses de période *P45* de séries temporelles d’images optiques Sentinel-2_L3A avec la légende à 9 classes : ■ : FRT; ■ : PRA; ■ : ARB; ■ : AGR; ■ : SFE; ■ : ZHU; ■ : RIV; ■ : RTE; ■ : BTM, de la zone d’intérêt *T32NPL*.

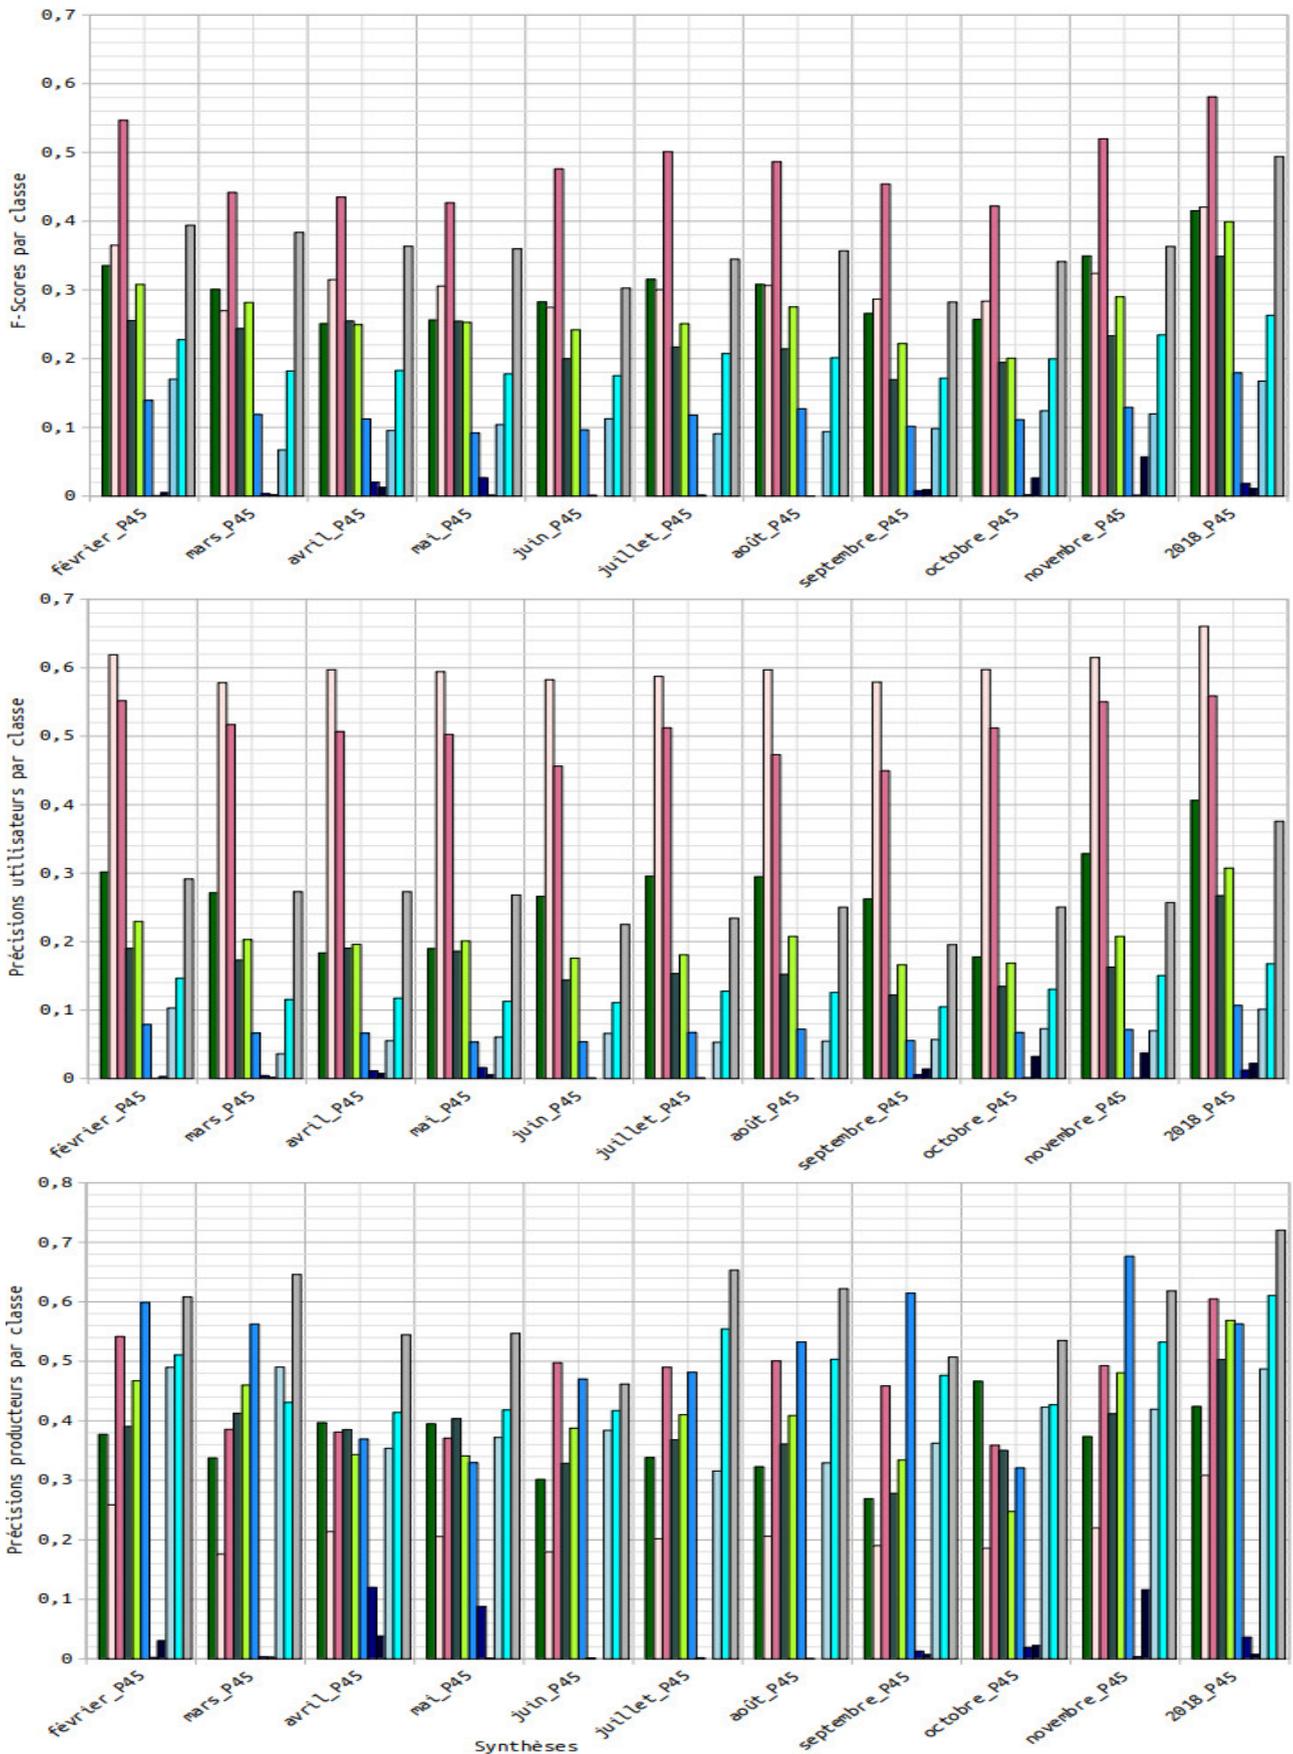


FIG. 4.68 – F-Scores et précision utilisateur et précision producteur par classe des classifications supervisées des synthèses de période *P45* de séries temporelles d’images optiques Sentinel-2_L3A avec la légende à 12 classes : ■ : VNC; ■ : VHB; ■ : FOU; ■ : FFE; ■ : TCU; ■ : ARB; ■ : ZHH; ■ : SFE; ■ : ZHU; ■ : RIV; ■ : RTE; ■ : BTM, de la zone d’intérêt T32NPL.

Afin de permettre l'analyse détaillée en comparant par paire de classes **des erreurs de classification utilisant le scénario STR3(P45)B avec la synthèse 2018_P45 de séries temporelles d'images optiques par rapport au scénario STR12B se fondant sur les séries temporelles elles-mêmes de l'année complète 2018**, les Tableaux 4.31, 4.32 et 4.33 présentent les matrices de confusion des classifications supervisées de la synthèse 2018_P45 utilisant respectivement les légendes à 5, 9 et 12 classes sur la zone d'intérêt T32NPL. Pour toutes les légendes, quelques confusions persistent entre les classes en dépit de la fusion précoce des synthèses mensuelles de période P45 (2018_P45) de séries temporelles d'images optiques seules.

Dans ces Tableaux, les pixels identifiés en classe VGT se trouvent presque plus classifiés en AGR et le taux de FP, avec la classe AGR, baisse de 15,7% à 10,1% avec l'utilisation de la synthèse 2018_P45 de séries d'images optiques Sentinel-2 seules pour la légende à 5 classes. La confusion s'atténue également avec l'utilisation des classes FRT et ARB et les taux de FP baissent de 9,2% à 6,2% pour la classe FRT et de 20% à 17,8% pour la classe ARB. Par contre, la confusion s'accroît plutôt avec l'utilisation de la classe PRA, et le taux de FP augmente fortement de 2% à 20,1%. Concernant la confusion avec la classe EAU, elle s'atténue et les taux de FP baissent pour les légendes à 5 et 9 classes. De plus, cette confusion reste très faible avec l'ajout de nouvelles classes pour la légende à 12 classes. C'est ainsi que **la confusion entre les classes VNC et RIV s'atténue avec un taux de FP qui n'évolue presque pas de 0,1% à 0,3%. Cette diminution de FP se fait au détriment des FN, avec une forte augmentation de ceux-ci lors de l'utilisation de la synthèse 2018_P45 de séries d'images optiques seules.**

Par ailleurs, avec la synthèse 2018_P45 de séries d'images optiques pour la légende à 5 classes sur la zone d'intérêt T32NPL, la classe RTE est classifiée en AGR avec un taux de FP=19,8%. À l'inverse, la classe AGR est classifiée en RTE avec un taux inférieur de FN=13,9%. Ce taux baisse à FN=13,3% de même que le taux de FP qui devient FP=17,5% et la confusion s'atténue donc légèrement pour la légende à 9 classes. De plus, pour cette légende, les classes SFE et RIV sont classifiées en RTE et ARB avec des taux de FP=16,3% et FP=9,9% respectivement. Inversement, les classes RTE et ARB sont classifiées en SFE et RIV avec des taux très inférieurs de FN=0,1% et FN=4,3%. Ces taux restent constants ou baissent encore et deviennent FN=0,2% et FN=0,5% de même que les taux de FP qui deviennent respectivement FP=16,8% et FP=0,8% et les confusions s'atténuent donc pour la légende à 12 classes. En outre, pour la légende à 9 classes, la classe RTE est classifiée en RIV avec un taux de FP=15,3%. À l'inverse, la classe RIV est classifiée en RTE avec un taux très inférieur de FN=3,1%. Ce taux reste constant contrairement au taux de FP qui baisse drastiquement à FP=4,4% et la confusion s'atténue donc pour la légende à 12 classes. En général, **les taux de FN augmentent et la discrimination entre les classes d'OCS est ici meilleure en utilisant la synthèse 2018_P45 de séries temporelles d'images optiques Sentinel-2_L3A seules pour les légendes à 9 et 12 classes.**

TAB. 4.31 – Matrice de confusion de la synthèse 2018_P45 avec la légende à 5 classes.

L3A_P45		Vérité Terrain					PU
% VU	CL	VGT	AGR	EAU	RTE	BTM	
11,8	VGT	80,0	13,0	18,5	8,1	0,1	97,3
77,1	AGR	10,1	67,5	8,4	19,8	3,1	49,1
2,2	EAU	6,8	4,5	70,3	2,9	0,6	3,2
0,1	RTE	1,9	13,9	2,6	63,7	23,3	8,9
0,1	BTM	0,1	1,1	0,2	5,5	72,9	34,5
	PP	80,0	67,5	70,3	63,7	72,9	

TAB. 4.32 – Matrice de confusion de la synthèse 2018_P45 avec la légende à 9 classes.

L3A_P45		Vérité Terrain										PU
% VU	CL	FRT	PRA	ARB	AGR	SFE	ZHU	RIV	RTE	BTM		
0,8	FRT	84,3	3,2	7,2	12,1	16,0	1,9	21,0	8,8	0,1	96,5	
7,4	PRA	0,1	62,6	0,1	0,6	0,1	0,1	0,1	0,1	0,0	3,2	
4,1	ARB	5,2	6,4	65,0	12,0	22,0	2,9	9,9	5,4	1,3	47,6	
77,1	AGR	6,2	20,1	17,8	58,9	0,2	21,1	7,0	17,5	2,8	56,3	
4,2	SFE	0,1	0,2	0,1	0,1	36,1	0,2	0,3	0,1	0,3	0,0	
0,9	ZHU	0,2	0,1	0,2	0,1	0,1	48,8	0,2	0,1	0,1	3,3	
0,2	RIV	3,3	0,9	4,3	2,3	7,8	24,0	58,3	15,3	0,2	4,2	
0,1	RTE	0,8	5,8	5,2	13,3	16,3	1,2	3,1	61,2	22,7	10,5	
0,1	BTM	0,1	1,0	0,4	0,9	1,7	0,1	0,3	5,4	72,9	36,2	
	PP	84,3	62,6	65,0	58,9	36,1	48,8	58,3	61,2	72,9		

TAB. 4.33 – Matrice de confusion de la synthèse 2018_P45 avec la légende à 12 classes.

L3A_P45		Vérité Terrain												PU
% VU	CL	VNC	VHB	FOU	FFE	TCU	ARB	ZHH	SFE	ZHU	RIV	RTE	BTM	
0,1	VNC	80,3	0,3	0,2	0,1	0,2	0,2	0,1	0,1	0,1	0,1	0,1	0,2	0,0
0,6	VHB	0,1	42,4	10,8	1,4	4,1	22,5	2,6	0,5	0,1	0,5	1,9	0,3	40,6
4,5	FOU	0,2	14,9	30,8	16,8	9,0	9,3	4,3	12,5	0,1	5,2	6,0	0,9	66,1
0,5	FFE	0,2	8,1	23,4	60,5	7,5	2,4	5,2	3,6	0,7	17,9	12,5	0,6	55,9
45,0	TCU	0,1	2,7	6,6	3,6	50,3	1,8	0,3	0,9	0,1	4,5	6,8	3,3	26,7
18,2	ARB	0,1	20,5	11,4	1,2	4,7	56,9	1,3	0,2	0,2	0,8	2,3	0,6	30,7
11,5	ZHH	0,2	0,8	0,5	0,5	0,2	0,1	56,3	1,9	32,3	17,5	0,1	0,1	10,7
4,2	SFE	0,3	0,1	0,1	0,1	0,1	0,1	2,0	23,2	0,2	1,4	0,2	0,1	1,2
0,9	ZHU	0,3	0,1	0,1	0,1	0,1	0,1	0,4	0,1	36,7	0,1	0,1	0,2	2,2
0,2	RIV	0,3	0,1	4,3	10,1	3,0	0,5	26,3	40,4	29,9	48,7	4,4	0,3	10,1
0,1	RTE	0,3	8,3	10,9	5,4	16,7	5,9	1,2	16,8	0,2	3,2	61,1	22,0	16,8
0,1	BTM	0,2	0,8	1,3	0,5	4,4	0,7	0,2	0,1	0,1	0,2	4,9	72,0	37,6
	PP	80,3	42,4	30,8	60,5	50,3	56,9	56,3	23,2	36,7	48,7	61,1	72,0	

% VU : pourcentage de données vecteurs utilisées.

CL : classification.

4.7.2.2 Utilisation des confiances des classifications supervisées de la zone d'intérêt T32NPL

Les Figures 4.56B, 4.57B et 4.58B montrent les extraits de cartes de confiance respectives des extraits de classifications supervisées des synthèses 2018_P45, 2018_P105 et 2018_P165 pour la légende à 9 classes de la zone d'intérêt T32NPL produites dans les Figures 4.56A, 4.57A et 4.58A.

Étant donné que la confiance est aussi influencée par la période de synthèse de séries temporelles d'images optiques Sentinel-2, on peut remarquer, ici, que les valeurs de confiance augmentent globalement et localement avec la période de synthèse comme c'est le cas par exemple pour les classes PRA et AGR dont les valeurs de confiance sont plus élevées pour la période P165 que pour la période P105. Par ailleurs, les classes RIV et RTE sont représentées avec plus de confiance pour la période P165 que pour la période P105 de même que les classes FRT et ARB. La génération de synthèses a ainsi permis de se débarrasser de quelques résidus de nuages et leurs ombres et d'améliorer localement la confiance de classification de la plupart des classes d'OCS avec les synthèses de grandes périodes. D'où la facile reconnaissance des classes PRA et AGR dans la partie est de la Figure 4.58B.

4.7.2.3 Evaluation qualitative des classifications supervisées de la zone d'intérêt T32NPL

De façon identique à la zone d'intérêt T33PUL, une évaluation visuelle permet d'analyser différents problèmes identifiés sur la zone d'intérêt T32NPL.

4.7.2.3.1 Paysages difficiles dans les classifications supervisées de la zone d'intérêt T32NPL Les métriques quantitatives n'étant pas en mesure de révéler tous les types d'erreurs présentes dans les classifications de grandes étendues, l'étude qualitative comparative visuelle des classifications des trois synthèses 2018_P45, 2018_P105 et 2018_P165 pour la légende à 9 classes est également détaillée dans cette section, sur deux types de zones : **une zone rurale (Figure 4.69) et une zone urbaine (Figure 4.70) sur la zone d'intérêt T32NPL.**

La zone rurale de la Figure 4.69A est la même que celle décrite dans la Figure 4.25A. Les différentes classifications et confiances de classification des synthèses 2018_P45, 2018_P105 et 2018_P165 pour la légende à 9 classes sont représentées sur les Figures 4.69B-F. Ici, les classes FRT ; PRA et ARB ressortent et se distinguent mieux avec la synthèse 2018_P165 sur la Figure 4.69C : **la classification de la synthèse 2018_P165 permet dans ce cas de mieux détecter et discriminer les classes de végétation contrairement à celle de la synthèse 2018_P45 qui ne permet pas de ressortir et d'identifier clairement les classes de végétation.** On peut également noter que la confusion entre les classes FRT et SFE est réduite. Sur la Figure 4.69C (synthèse 2018_P165), la classification de la classe SFE est meilleure. En effet, les surfaces d'eau ressortent clairement et précisément, il y a toutefois un peu de confusion avec la classe FRT. De la même manière, la classe FRT est assez bien représentée dans la classification de la synthèse 2018_P105 (Figure 4.69B). Cependant, mise à part ces quatre classes, les autres rencontrent encore des problèmes. Par exemple, la classe AGR qui contient des zones d'ombres est confondue partiellement avec la classe PRA dans la classification de la synthèse 2018_P165 (Figure 4.69C). De même, la classe SFE est confondue presque intégralement avec la classe AGR dans la classification de la synthèse 2018_P45 (Figure 4.69D).

Les classifications des synthèses 2018_P105 et 2018_P165 des Figures 4.70A et 4.70C(D) sont effectuées pour la légende à 9 classes sur la zone urbaine de la Figure 4.70B décrite dans la Figure 4.26B. Avec la synthèse 2018_P105, la classification des classes PRA et AGR (Figure 4.70A) donne de plus bons résultats permettant de mieux les distinguer avec des confusions réduites apparaissant entre ces classes. Cette dernière synthèse a permis de séparer les zones mélangées découlant de polygones grossiers au sein des données d'apprentissage et d'améliorer la qualité de la classification. De plus, la classification des classes RIV et RTE donne de meilleurs résultats avec la synthèse 2018_P165 (Figure 4.70C(D)), même si les classes PRA et AGR restent toujours confondues par endroits. **Cette confusion, que l'on avait déjà observée sur la zone rurale, pourrait être facilement supprimée par exemple en utilisant les synthèses mensuelles de séries temporelles de la combinaison d'images optiques et radar Sentinel-1_L1/-2_L3A.**

4.7.2.3.2 Petites classes locales dans les classifications supervisées de la zone d'intérêt T32NPL

Les classes minoritaires rencontrent toujours des difficultés à être correctement cartographier en raison du manque de leurs échantillons représentatifs pour l'entraînement des classifieurs. Des exemples typiques sont les classes RTE ; BTM ; RIV et ZHU. Ces classes sont concentrées dans des régions spécifiques de la zone d'intérêt T32NPL. La Figure 4.71B illustre comment **la classification de la synthèse 2018_P105 réduit la confusion entre les classes AGR et SFE.**

4.7.2.4 Comparaison pixel à pixel des classifications supervisées de la zone d'intérêt T32NPL

L'objectif de cette section est d'effectuer la comparaison pixel à pixel entre les classifications des différentes synthèses mensuelles et de leurs fusions précoces en fonction des périodes de séries temporelles d'images optiques de la zone d'intérêt T32NPL.

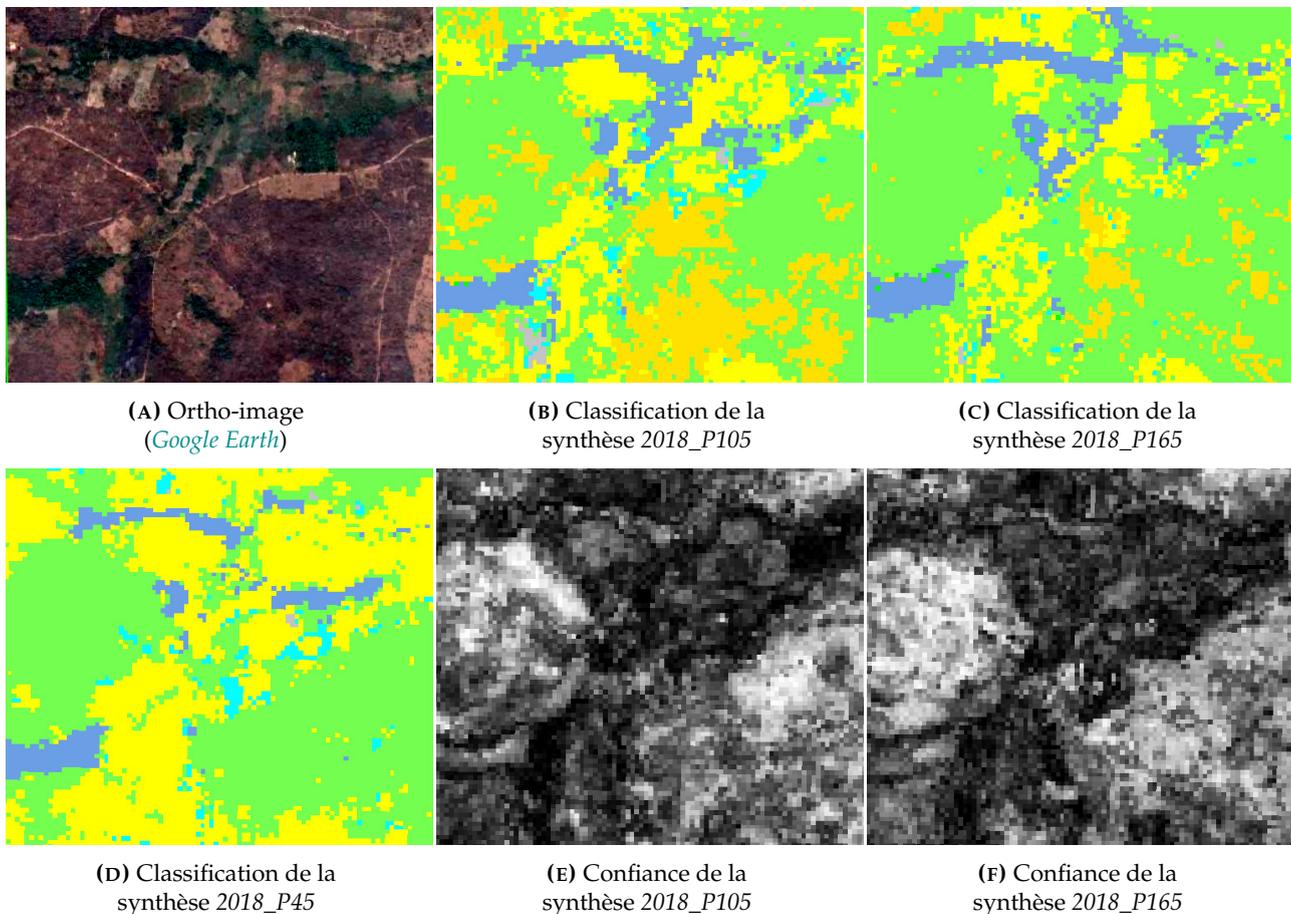


FIG. 4.69 – Extraits de l'ortho-image et des classifications et des confiances de classifications des synthèses 2018_P45, 2018_P105 et 2018_P165 de séries d'images optiques Sentinel-2_L3A avec la légende à 9 classes, d'une zone rurale sur la zone d'intérêt T32NPL.

Les Tableaux 4.34 et 4.35 présentent les différentes valeurs du coefficient Kappa (K) et du F-Score moyen (FS) obtenues au terme de la comparaison pixel à pixel des classifications des différentes synthèses mensuelles de périodes 105 et 165 et de leurs fusions précoces respectives 2018_P105 et 2018_P165 de séries temporelles d'images optiques Sentinel-2_L3A et de la vérité terrain (VT) pour la légende à 9 classes, de la zone d'intérêt T32NPL.

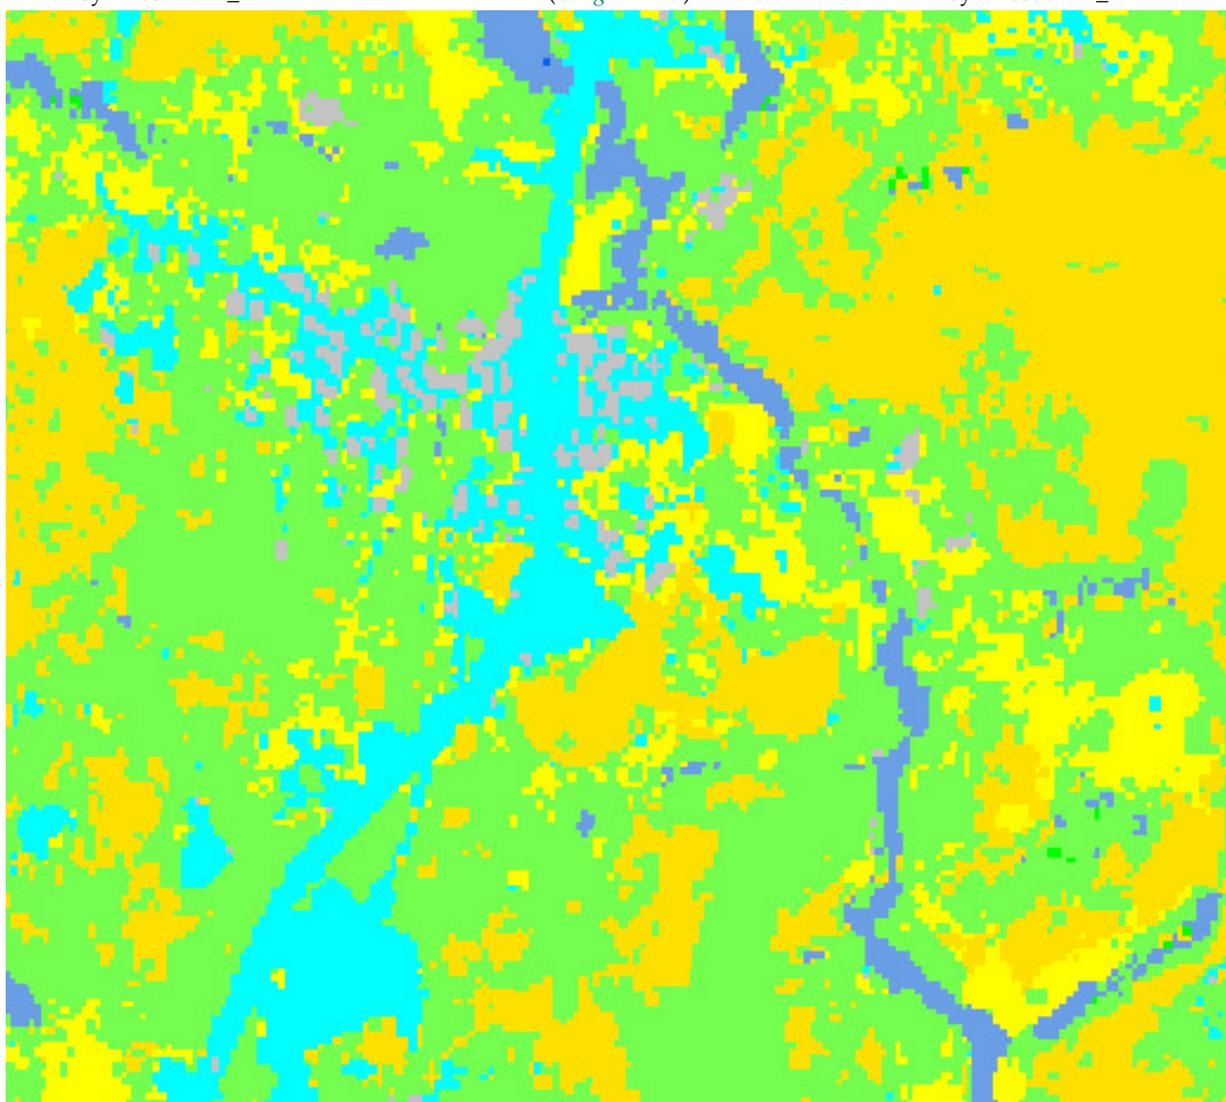
Dans ces tableaux, on peut globalement observer que seules les classifications des synthèses mensuelles juillet_P105 et septembre_P105 de périodes 105 jours ne s'accordent pas avec la VT. De plus, on peut remarquer des scores de similarité K et FS moyens issus des comparaisons entre les classifications des différentes synthèses de périodes 105 et 165 jours et la VT, traduisant ici leur rapprochement. Ce qui implique **des taux d'accord moyens entre les différentes classifications. Les valeurs de K et de FS sont plus élevées dans chacune des classifications des synthèses (mars_P105, novembre_P105 et 2018_P105) de périodes 105 jours et (avril_P165, octobre_P165 et 2018_P165) de périodes 165 jours par rapport aux autres classifications des synthèses aux périodes respectives et la VT qui possèdent ainsi les meilleurs taux d'accord.** Au contraire, les classifications des synthèses mensuelles septembre_P105 et juillet_P165 possèdent les plus faibles taux d'accord par rapport au reste des classifications des synthèses de périodes respectives 105 et 165 jours et la VT.



(A) Classification de la synthèse 2018_P105

(B) Ortho-image (Google Earth)

(C) Classification de la synthèse 2018_P165



(D) Zoom sur l'extrait de la classification de la synthèse 2018_P165

FIG. 4.70 – Extraits des classifications des synthèses 2018_P45, 2018_P105 et 2018_P165 de séries temporelles d'images optiques Sentinel-2_L3A avec la légende à 9 classes :
 ■ : FRT; ■ : PRA; ■ : ARB; ■ : AGR; ■ : SFE; ■ : ZHU; ■ : RIV; ■ : RTE; ■ : BTM, d'une zone urbaine sur la zone d'intérêt T32NPL.

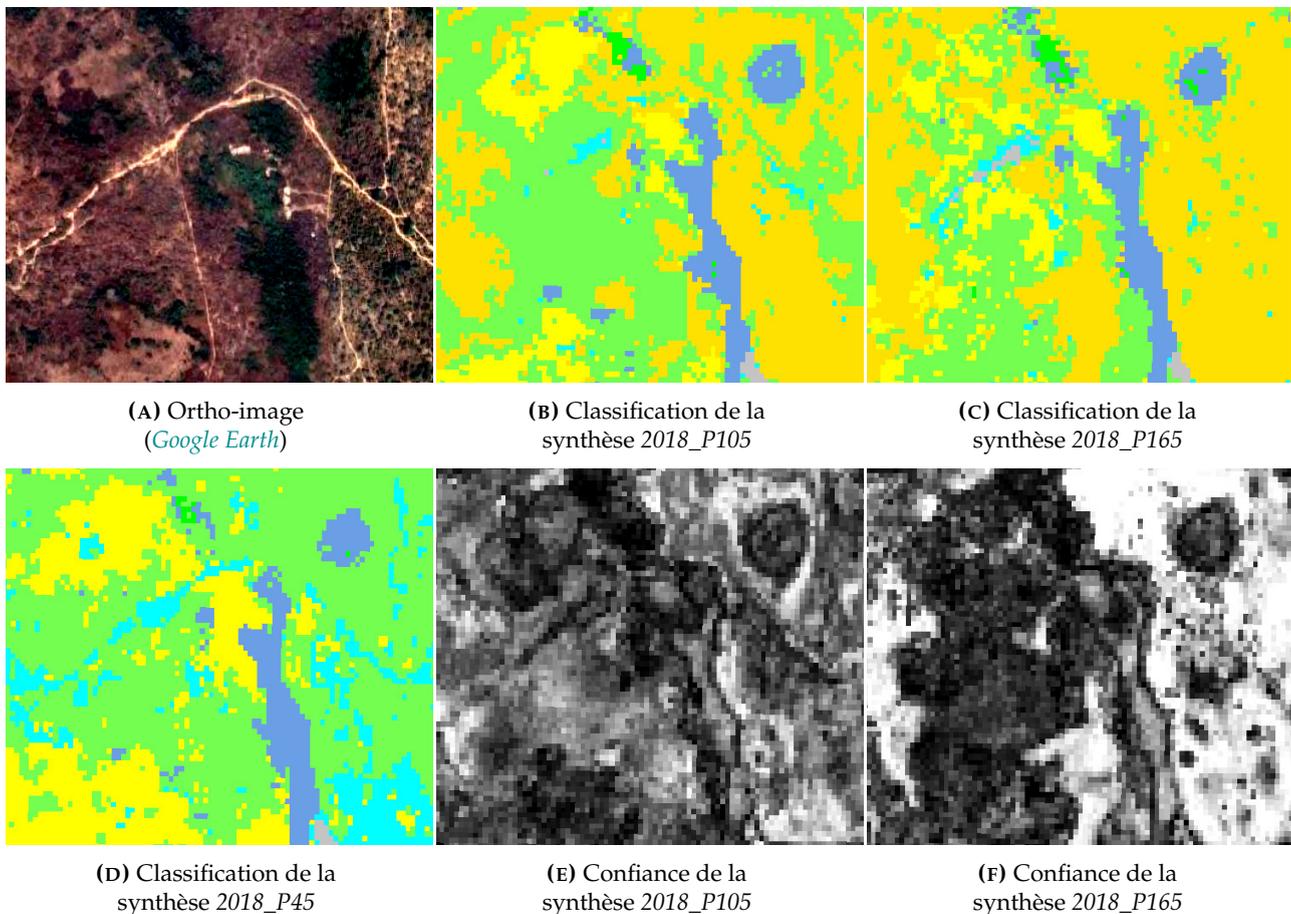


FIG. 4.71 – Extraits de l'ortho-image et des classifications et des confiances de classifications des synthèses 2018_P45, 2018_P105 et 2018_P165 de séries d'images Sentinel-2_L3A avec la légende à 9 classes, de petites classes locales sur la zone d'intérêt T32NPL.

4.7.2.5 Comparaison par région des distributions de classes des classifications supervisées de la zone d'intérêt T32NPL

L'objectif de cette section est de comparer en effectuant la moyenne des scores calculés au sein de grandes régions extraites des classifications des différentes synthèses mensuelles et de leurs fusions précoces de séries temporelles d'images optiques, de la zone d'intérêt T32NPL.

Les Tableaux 4.36 et 4.37 présentent les moyennes des scores calculés au sein de cellules de taille 200 pixels extraites des classifications des synthèses de périodes respectives 105 et 165 jours de séries temporelles d'images optiques Sentinel-2_L3A et de la vérité terrain (VT) pour la légende à 9 classes, de la zone d'intérêt T32NPL. Le Tableau 4.36 montre globalement que les scores sont plus faibles que ceux de la zone d'intérêt T33PUL en comparant par région des classifications des synthèses de périodes 105 jours et la VT. Cependant, cette dernière diffère faiblement de toutes les classifications des synthèses avec des valeurs des scores les plus élevées allant seulement de 0,25 à 0,33. Plus précisément, **les classifications des synthèses novembre_P105 et 2018_P105 sont les plus proches de la VT avec des valeurs faibles respectives de 0,31 et 0,25. Par ailleurs, les classifications des synthèses novembre_P105 et 2018_P105 se rapprochent en étant toutes les deux les plus éloignées des autres classifications de synthèses avec les fortes valeurs des scores de 0,13 à 0,31, ce qui explique leur bonne qualité. Par contre, les classifications des deux groupes de synthèses mensuelles (mai_P105,**

TAB. 4.34 – Coefficients Kappa (K) et F-Scores moyens (FS) obtenus après comparaison pixel à pixel des classifications des synthèses de période 105 jours et la VT avec 9 classes.

	mar._P105		mai_P105		juil._P105		sep._P105		nov._P105		2018_P105		VT	
<i>k = 9</i>														
L3A_P105	K	FS	K	FS	K	FS	K	FS	K	FS	K	FS	K	FS
mars_P105	1,0	100,0	0,5	34,4	0,4	31,8	0,4	31,0	0,6	39,6	0,6	44,6	0,4	28,1
mai_P105	0,5	34,4	1,0	100,0	0,6	40,6	0,4	28,2	0,5	32,9	0,6	38,1	0,4	25,1
juillet_P105	0,4	31,8	0,6	40,6	1,0	100,0	0,4	28,8	0,5	32,5	0,5	37,1	0,4	24,3
septembre_P105	0,4	31,0	0,4	28,2	0,4	28,8	1,0	100,0	0,5	34,1	0,5	36,2	0,4	24,1
novembre_P105	0,6	39,6	0,5	32,9	0,5	32,5	0,5	34,1	1,0	100,0	0,6	44,1	0,4	27,8
2018_P105	0,6	44,6	0,6	38,1	0,5	37,1	0,5	36,2	0,6	44,1	1,0	100,0	0,5	36,6
VT	0,4	28,1	0,4	25,2	0,4	24,3	0,4	24,1	0,4	27,8	0,5	36,6	1,0	100,0

TAB. 4.35 – Coefficients Kappa (K) et F-Scores moyens (FS) obtenus après comparaison pixel à pixel des classifications des synthèses de période 165 jours et la VT avec 9 classes.

	avr._P165		juil._P165		oct._P165		2018_P165		VT	
<i>k = 9</i>										
L3A_P165	K	FS	K	FS	K	FS	K	FS	K	FS
avril_P165	1,0	100,0	0,5	38,7	0,5	39,2	0,6	48,8	0,4	28,8
juillet_P165	0,5	38,7	1,0	100,0	0,5	36,1	0,6	42,5	0,4	26,4
octobre_P165	0,5	39,2	0,5	36,1	1,0	100,0	0,6	47,9	0,4	29,7
2018_P165	0,6	48,8	0,6	42,5	0,6	47,9	1,0	100,0	0,5	36,3
VT	0,4	28,8	0,4	26,4	0,4	29,7	0,5	36,3	1,0	100,0

k : nombre de classes. VT : vérité terrain.

juillet_P105 et novembre_P105) et (mars_P105, mai_P105 et juillet_P105) se rapprochent de celles des deux synthèses mensuelles septembre_P105 et novembre_P105 avec de très faibles scores de 0,19 et 0,16 respectivement. De plus, les classifications des trois paires de synthèses (juillet_P105 et septembre_P105); (mars_P105 et septembre_P105) et (septembre_P105 et 2018_P105) se rapprochent de celles des trois synthèses mensuelles mars_P105; mai_P105 et juillet_P105 avec des faibles scores de 0,21 et 0,19 respectivement.

Selon le Tableau 4.37, les scores sont également plus faibles que ceux de la zone d'intérêt T33PUL en comparant par région des classifications des synthèses de périodes 165 jours et la VT. Cependant, cette dernière diffère très faiblement de toutes les classifications des synthèses avec des valeurs des scores les plus élevées de 0,25 à 0,33. Plus précisément, **les classifications des synthèses juillet_P165 et 2018_P165 sont les plus proches de la VT avec des valeurs faibles respectives de 0,31 et 0,25. Par ailleurs, les classifications des synthèses mensuelles avril_P165 et juillet_P165 se rapprochent en étant toutes les deux les plus éloignées des autres classifications de synthèses et la VT avec des valeurs plus élevées des scores de 0,14 à 0,32**, expliquant les bonnes qualités de ces synthèses mensuelles par rapport aux autres synthèses de même période.

Au cours des travaux, une ambiguïté a été rencontrée du fait de la manière dont les expériences ont été menées : augmenter la période de synthèse revient en effet à la fois à intégrer plus d'images dans le calcul des synthèses (et donc à lisser davantage au risque de « moyenner » des informations différentes) et à jouer sur la résolution temporelle de la série d'images (moins de dates). Ce qui signifie qu'on ne sait donc pas forcément quel mécanisme est la cause de ce que l'on observe.

<i>L3A_P105</i>	mar.	mai	juil.	sep.	nov.	2018	VT
mars	0.00	0.19	0.21	0.21	0.16	0.15	0.33
mai	0.19	0.00	0.10	0.19	0.16	0.17	0.33
juillet	0.21	0.10	0.00	0.19	0.16	0.19	0.33
septembre	0.21	0.19	0.19	0.00	0.19	0.20	0.33
novembre	0.16	0.16	0.16	0.19	0.00	0.13	0.31
2018	0.15	0.17	0.19	0.20	0.13	0.00	0.25
VT	0.33	0.33	0.33	0.33	0.31	0.25	0.00

TAB. 4.36 – Moyennes des distances entre histogrammes issues des classifications des synthèses de période 105 jours et de la VT avec 9 classes.

<i>L3A_P165</i>	avr.	juil.	oct.	2018	VT
avril	0.00	0.14	0.17	0.14	0.32
juillet	0.14	0.00	0.17	0.15	0.31
octobre	0.17	0.17	0.00	0.14	0.33
2018	0.14	0.15	0.14	0.00	0.25
VT	0.32	0.31	0.33	0.25	0.00

TAB. 4.37 – Moyennes des distances entre histogrammes issues des classifications des synthèses de période 165 jours et de la VT avec 9 classes.

4.8 Comparaison des classifications avec les autres produits d'OCS

Ainsi qu'on l'a vu précédemment, ces travaux se heurtent à une absence de vraies données de référence permettant de qualifier les résultats obtenus. Or, de nouveaux produits d'OCS sont parus récemment sur nos zones d'étude : Il apparaît donc intéressant de comparer nos résultats à ces produits (de légende un peu différente) qui n'ont d'ailleurs pas pu être qualifiés pour les mêmes raisons.

4.8.1 Comparaison des classifications et des produits d'OCS sur les zones d'intérêt

4.8.1.1 Zone d'intérêt T33PUL (ZONE1, Nord)

Sur la base des ensembles de données mondiaux, la qualité de la classification supervisée de la synthèse 2018_P45 pour la légende à 12 (CL12_2018 (CL12)) classes est comparée à celle de quatre autres produits GLC_2020 (GLC) (BUCHHORN et al., 2020), l'Occupation du SOI du Sahel (OSO_Sahel_2018 (OSO_Sahel) (VINCENT, INGLADA et PEÑA, 2022)), l'OCS mondiale dynamique de Google pour l'année 2022 (Google_Dynamic_Earth_2022 (GDE) (BROWN, BRUMBY et GUZDER-WILLIAMS, 2022)) et l'OCS mondiale de l'ESA pour l'année 2020 (ESA_World_Cover_2020 (ESA) (ZANAGA et al., 2021)) sur la zone d'intérêt T33PUL. Dans l'ensemble, la CL12 présente une bonne qualité de représentation des classes de la légende à 12 classes par rapport aux quatre précédents produits d'OCS. En ce qui concerne

les classes qui seraient pertinentes pour les études hydrologiques, nous observons que : les zones d'eau permanente et non permanente (inondation temporaire) sont mieux délimitées et les zones urbaines représentées dans les classifications par les classes RIV et BTM semblent moins compactes mais présentent une certaine confusion avec les classes de sol nu sur la *CL12*. De même, les zones de culture semblent moins compactes et clairsemées sur la *CL12*, ce qui semble réaliste dans certains cas.

4.8.1.1.1 Comparaison qualitative avec les produits *GLC*, *OSO_Sahel* et *GDE* En particulier, la *CL12* atteint de bonnes précisions de représentation en montrant une meilleure discrimination des classes de végétation que les *OSO_Sahel* et *GDE*. Comparativement à *GLC*, la *CL12* et les *OSO_Sahel* et *GDE* représentent mieux les différentes classes d'OCS, en particulier les classes d'eau.

De manière similaire, la *CL12* montre une représentation précise des classes d'OCS plus élevée suivi par les *OSO_Sahel* et *GDE*. De plus, la précision de la cartographie de la classe BTM de la *CL12* est de loin supérieure à celle des trois autres produits.

Afin d'illustrer la qualité de représentation des différentes classes de chaque produit d'OCS, une région typique située au sud-ouest de la zone *T33PUL* et couvrant un environnement climatique et paysager représentatif, a été sélectionnée sur la Figure 4.72. Dans l'ensemble, la *CL12* et les *OSO_Sahel* et *GDE* présentent une plus grande cohérence spatiale en représentant avec précision les distributions spatiales des différents types de classes d'OCS. Par contre, le produit *GLC* montre une répartition spatiale beaucoup plus grossière source de données différentes des trois autres produits. C'est ainsi que la classe identifiée par *GLC* comme étant la classe VGT, se confond à la classe AGR dans la *CL12* et les *OSO_Sahel* et *GDE*.

De façon plus détaillée, la *CL12* et les *OSO_Sahel* et *GDE* présentent une distribution spatiale similaire des classes d'OCS prédominantes (Figures 4.72B, 4.72D et 4.72E). Enfin, la *CL12* et les *OSO_Sahel* et *GDE* discriminent difficilement les limites des classes agricoles, et la *CL12* présente des surfaces des classes de végétation plus grandes que celles des *OSO_Sahel* et *GDE* dans les zones boisées où les classes AGR et EAU se confondent (Figure 4.72B), contrairement aux trois autres produits, le *GLC* possède la plus grande surface de classe VGT qui se confond avec la classe AGR sur la Figure 4.72C. La *CL12* sur-détecte la classe EAU au détriment de la classe ARB.

4.8.1.1.2 Comparaison qualitative avec le produit *ESA* En plus de la comparaison avec les trois précédents produits d'OCS, la *CL12* a également été confrontée au produit *ESA* au sud-ouest de la zone *T33PUL* afin d'évaluer de manière exhaustive la qualité de ses résultats. La Figure 4.72 compare ces produits. Dans l'ensemble, la *CL12* est plus cohérente spatialement que le produit *ESA* dans lequel, les classes VGT et AGR se confondent sur la Figure 4.72F.

A grande échelle, la répartition géographique des classes majoritaires semble similaire. Cependant, la *CL12* présente des classes moins homogènes et semblent plus granulaires dans les zones de transition. On peut constater que les classes VGT et AGR diffèrent, probablement en raison d'échantillons d'entraînement différents et/ou de critères de définition des classes différents. La classe EAU semble mieux délimitée sur la *CL12*, en particulier les eaux non permanentes. Sur la *CL12*, la classe RTE est sur-détectée tandis que la classe BTM est plus finement.

Enfin, on peut remarquer que la *CL12* présente un grand avantage dans la représentation spatiale détaillée par rapport au produit *ESA*. Par exemple, les limites des classes FOU et FFE sont représentées avec plus de précision dans la *CL12* sur la Figure 4.72B tandis que le produit d'OCS plus grossier *ESA* n'est généralement pas détaillé. Par conséquent, la *CL12* présente non seulement des avantages

évidents en termes de détails spatiaux, mais corrige de nombreuses erreurs de classification et atteint une plus grande précision par rapport au produit d'OCS *ESA*.

Il convient de préciser que ces produits ont des nomenclatures différentes et n'ont pas été produits à partir des mêmes données par les mêmes traitements. Les *OSO_Sahel* et *GLC* sont assez proches (même nomenclature). Le produit *OSO_Sahel* a été entraîné à partir de *GLC* et en améliore le niveau de détail géométrique. La *CL12* et le produit *OSO_Sahel* s'appuient sur les mêmes outils/données mais ont été entraînés à des « échelles différentes » (plus ou moins de tuiles Sentinel-2) et une légende un peu différente. Le *GDE* est plus proche de la *CL12* tandis que le produit *ESA* est un peu intermédiaire entre *GDE* et les autres produits.

4.8.1.2 Zone d'intérêt *T32NPL* (*ZONE2*, Ouest-Centre)

Ici, la qualité des classifications supervisées de la synthèse [2018_P45](#) pour les légendes à 5 ([CL5_2018](#) (*CL5*)) et 12 ([CL12_2018](#) (*CL12*)) classes est comparée à celle des trois produits *GLC*, *GDE* et *ESA*; l'*OSO_Sahel* n'étant pas encore disponible sur la zone d'intérêt *T32NPL*. En général, les classifications *CL5* et *CL12* présentent la meilleure qualité de représentation des classes des légendes à 5 et 12 classes par rapport aux trois précédents produits d'OCS. En particulier, les *CL5* et *CL12* montrent une meilleure détection du chevelu hydrographique que les autres produits mais au prix d'une sur-détection au détriment des arbres. Contrairement à la zone d'intérêt *T33PUL*, la classe RTE est ici sur-détectée et peut être assimilée à de la tâche urbaine. Toutefois, ces classifications présentent le problème des zones d'eau non permanentes avec la présence de la classe RIV qui se confond à la classe RTE en saison sèche. Nous observons que les zones d'eau permanente et non permanente sont mieux représentées et les zones urbaines semblent moins compactes mais présentent une certaine confusion avec les classes de sol nu sur la *CL12*. De même, les zones de culture semblent moins compactes et clairsemées sur la *CL12* se rapprochant de la réalité.

4.8.1.2.1 Comparaison qualitative avec les produits *GLC* et *GDE* En particulier, la *CL5* montre une meilleure discrimination des classes VGT; EAU et RTE que le *GLC* et atteint des précisions de représentation similaires à celles de *GDE* pour les cinq types de classes d'OCS. Comparativement à *GLC*, la *CL12* et le *GDE* représentent mieux les classes de la légende à 12 classes, en particulier les classes FOU et FFE.

De manière similaire, la *CL12* montre une précision de représentation des classes d'OCS plus élevée suivi par le produit *GDE*. Bien que les trois produits d'OCS montrent une bonne représentation des classes de forêts et de surfaces d'eau, la précision de la cartographie des classes FOU et FFE de la *CL12* est supérieure à celle des trois autres produits.

Afin d'illustrer la qualité de représentation des différentes classes de chaque classification et produit d'OCS, une région typique couvrant un environnement climatique et paysager représentatif, a été sélectionnée sur la Figure 4.73. Dans l'ensemble, les *CL5*, *CL12* et *GDE* présentent une plus grande cohérence spatiale en représentant avec précision les distributions spatiales des différentes classes d'OCS. Par contre, le produit *GLC* montre une répartition spatiale différente. C'est ainsi que les classes identifiées par *GLC* comme étant les classes PRA et ARB, se confondent aux classes TCU et FRT dans la *CL12* et le *GDE*.

Du point de vue de la diversité de l'OCS, on constate aisément que les *CL5* et *CL12* présentent des avantages significatifs par rapport aux trois autres produits. De façon plus détaillée, la distribution spatiale des classes prédominantes du produit *GDE* se rapproche de celle des classifications (Figure

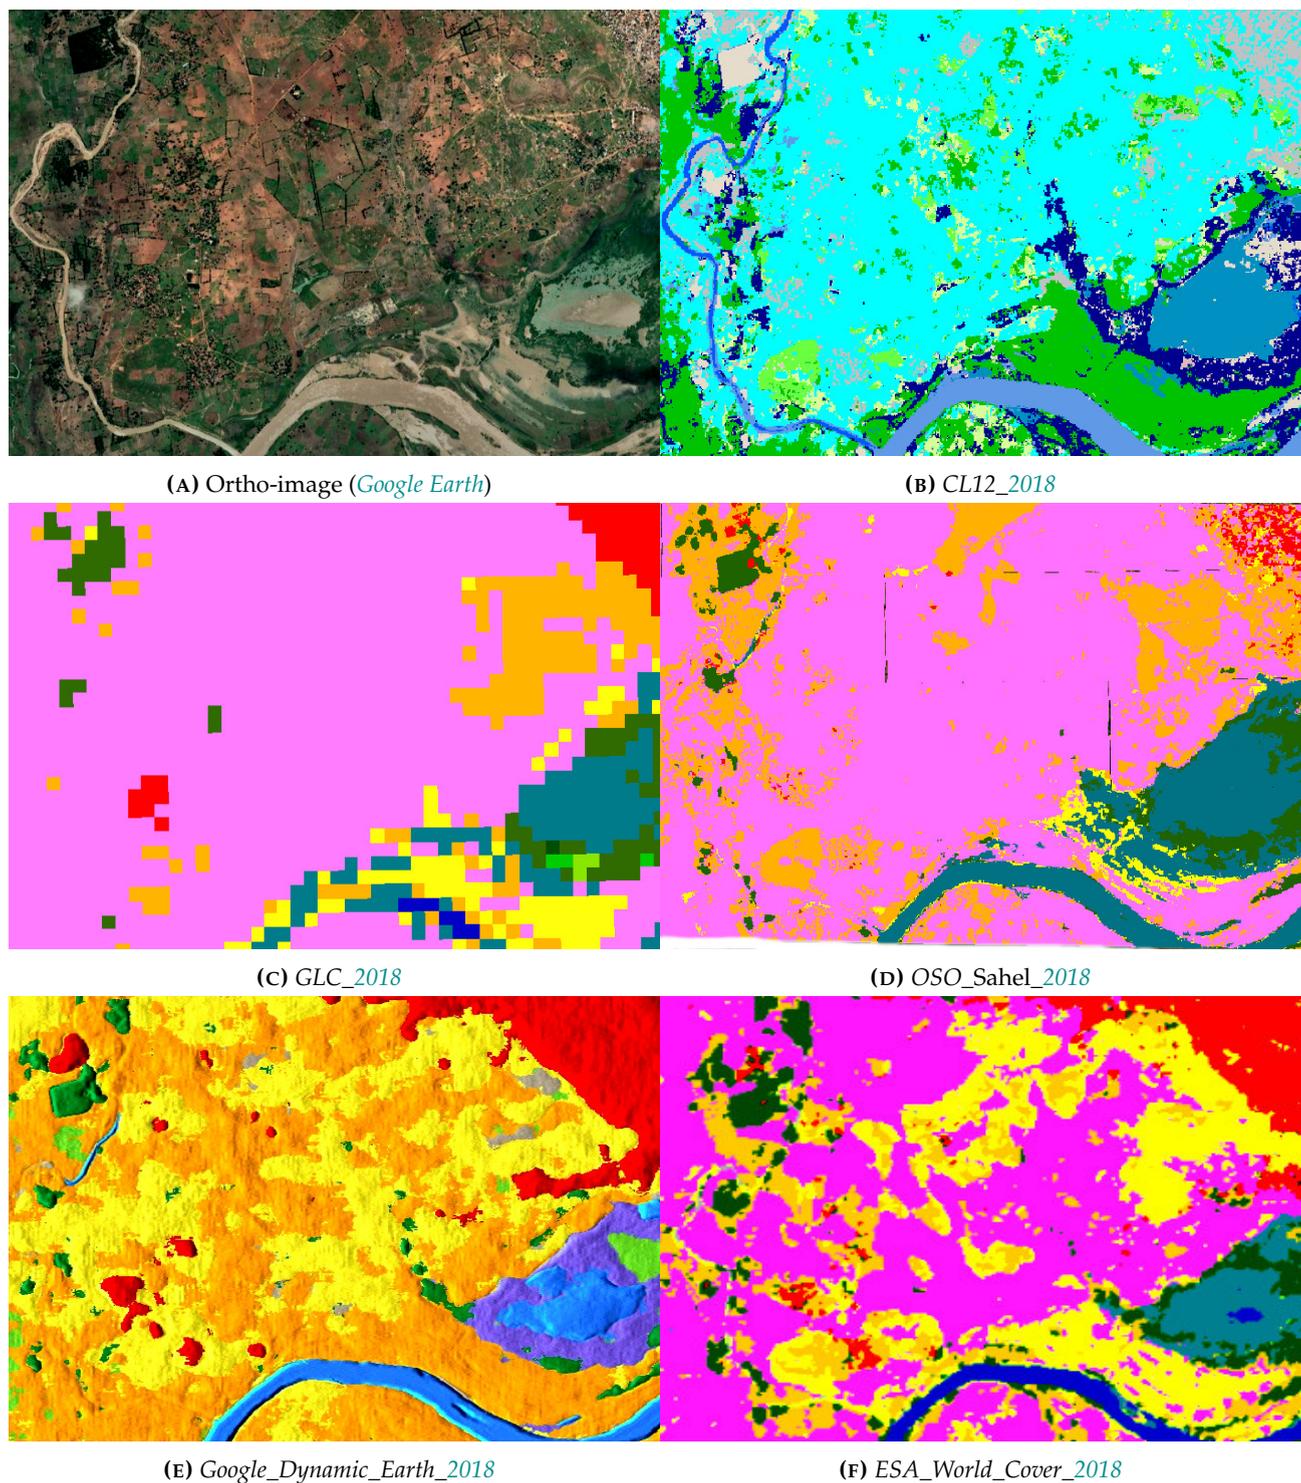


FIG. 4.72 – Comparaison entre la classification de la synthèse 2018_P45 avec la légende à 12 classes et d'autres produits d'OCS dans une région de $300m \times 500m$ de la zone T33PUL.

4.73E). Cependant, le produit *GLC* confond la classe TCU avec les classes PRA et FRT (Figure 4.73D). Enfin, les *CL5*, *CL12* et *GDE* discriminent avec précision les limites des classes agricoles, et la *CL12* présente des surfaces de la classe AGR plus grandes que celles des *CL5* et *GDE* dans les zones boisées où les classes FRT et AGR se confondent (Figure 4.73C), ce qui démontre l'avantage d'une cartographie avec un grand nombre de classes sur de grandes surfaces. Contrairement aux deux autres produits, le produit *GDE* possède la plus grande surface de classe PRA en confondant la classe FRT avec la classe PRA sur la Figure 4.73E.

4.8.1.2.2 Comparaison qualitative avec le produit *ESA* En plus de la comparaison avec les deux précédents produits d'OCS, les *CL5* et *CL12* ont également été confrontées au produit *ESA* sur la zone d'intérêt *T32NPL* afin d'analyser de manière exhaustive la qualité de leurs résultats. La Figure 4.73 compare intuitivement les qualités des *CL5* et *CL12* et du produit *ESA*. Dans l'ensemble, les *CL5* et *CL12* sont plus cohérentes spatialement que le produit *ESA* dans lequel, les classes PRA et FRT se confondent sur la Figure 4.73F.

Enfin, on peut constater que la *CL12* présente un grand avantage dans la représentation spatiale détaillée par rapport au produit *ESA*. Par exemple, les limites des classes RIV; SFE et RTE sont représentées avec plus de précision dans la *CL12* sur la Figure 4.73B tandis que le produit d'OCS plus grossier *ESA* n'est généralement pas détaillé. Par conséquent, la *CL12* présente non seulement des avantages évidents en termes de détails spatiaux, mais corrige de nombreuses erreurs de classification et atteint une plus grande précision par rapport au produit d'OCS *ESA*.

4.8.2 Enseignements tirés

Nous avons trouvé une solution innovante pour la cartographie de l'OCS sur de très grandes zones sans avoir recours à des enquêtes de terrain coûteuses ou à des campagnes de photo-interprétation intensives. En effet, en tirant parti de cartes existantes à plus faible résolution, pour lesquelles des données de référence ont été utilisées, nous avons obtenu un produit à haute résolution spatiale qui semble être comparable à des produits similaires pour lesquels des données de référence ont été spécialement collectées.

Les travaux de classification réalisés ont été limités par le manque de données de référence pour l'étape de validation. Cela a deux conséquences principales : 1) il est impossible de donner une évaluation précise de la qualité du produit, et 2) nous ne pouvons pas non plus déterminer si les désaccords avec les autres produits d'OCS proviennent d'erreurs de classification ou de la résolution spatiale accrue de notre produit.

Malheureusement, les données de référence collectées pour les produits existants ne sont pas accessibles au public, bien que certains d'entre eux (*GLC* ou *ESA* par exemple) soient financés par des fonds publics. Ce type de données aurait pu être utilisé pour évaluer la qualité de notre produit.

Du point de vue hydrologique, la *CL12* semble fournir une meilleure cartographie des zones d'eau, principalement autour des bassins versants et des zones humides par rapport aux trois autres produits mondiaux d'OCS disponibles (*GLC*, *OSO_Sahel* et *ESA*), ce qui aiderait à définir des modèles de rivière (largeur des rivières et des plaines d'inondation). Les zones de culture semblent similaires entre les produits et enfin, les zones urbaines et végétalisées sont mieux représentées dans le produit *ESA*.

On pourrait se demander pourquoi nous avons produit la *CL12* si d'autres produits étaient disponibles. C'est surtout parce que ces produits n'existaient pas au début des travaux. C'est qu'en décrivant

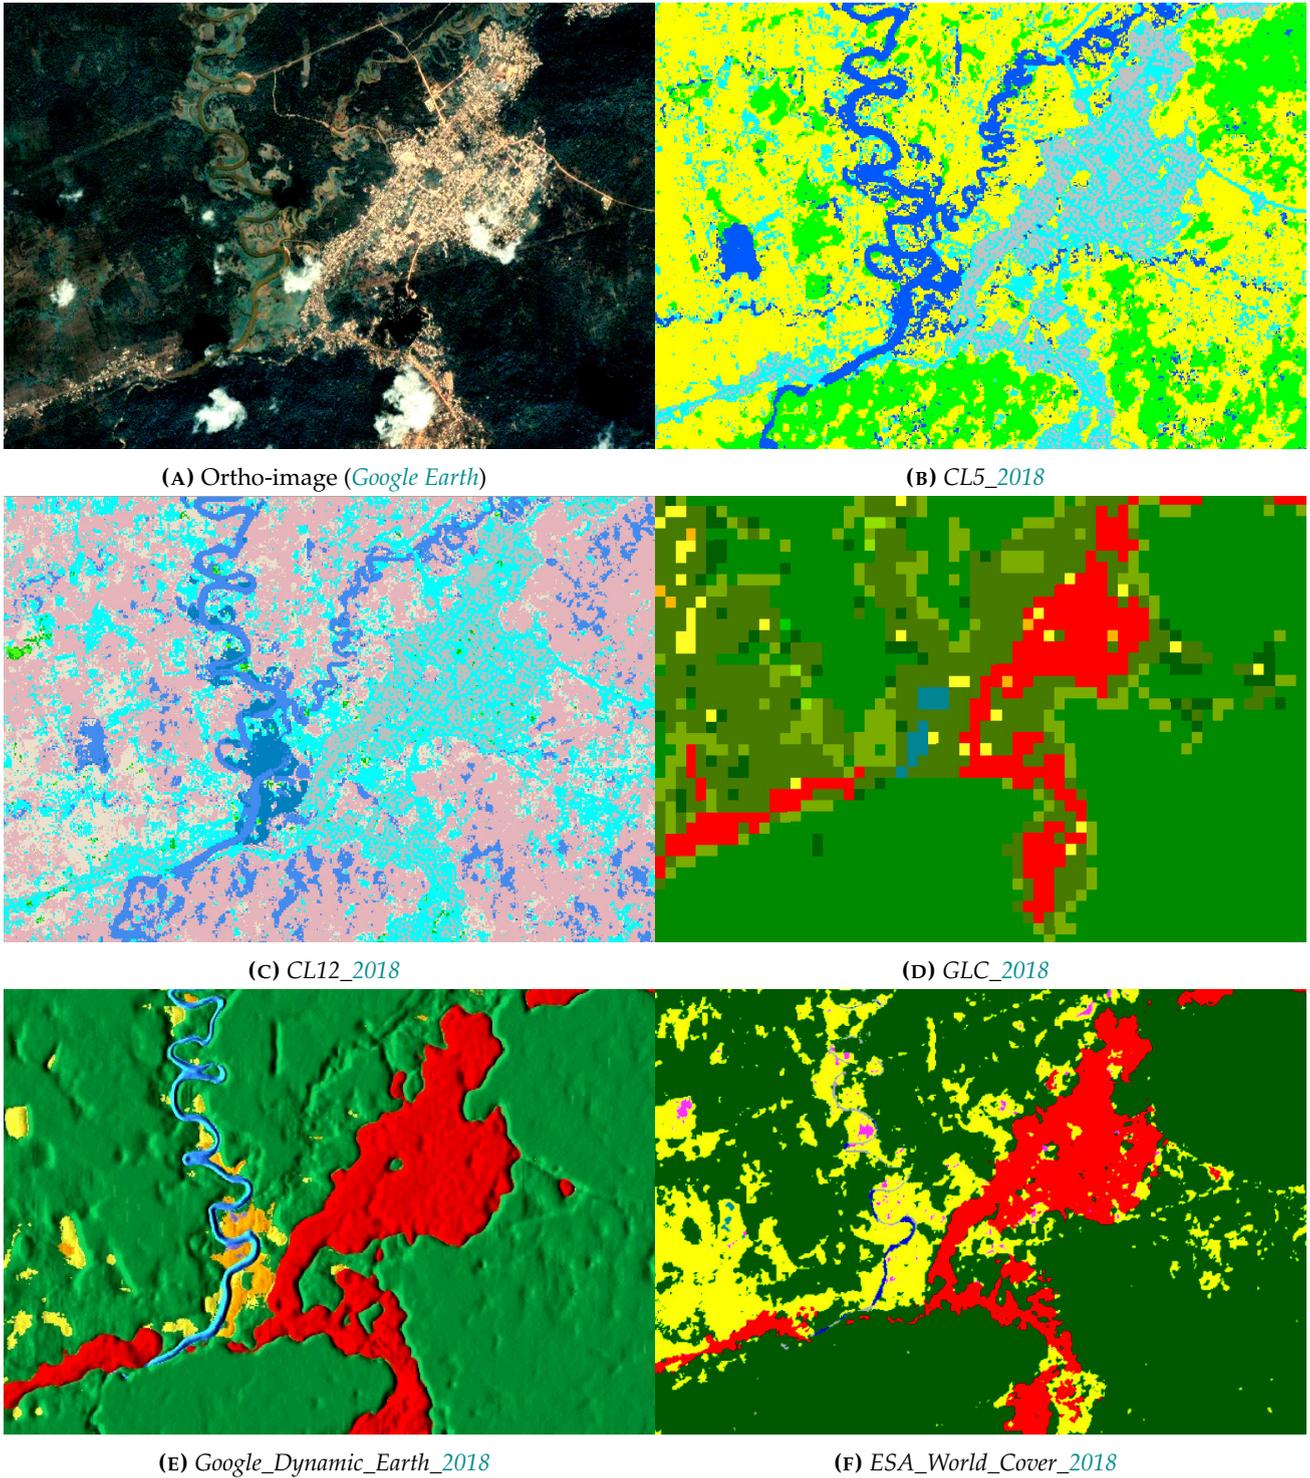


FIG. 4.73 – Comparaison entre les classifications de la synthèse *2018_P45* avec les légendes à 5 et 12 classes et d'autres produits d'OCS dans une région de $300m \times 500m$ de la zone *T32NPL*.

les mêmes problèmes liés aux données, (VINCENT, INGLADA et PEÑA, 2022) ont démontré que la chaîne *iota*² peut s'étendre au-delà de la cartographie à l'échelle d'un pays.

Le dernier point qui mérite d'être souligné est que la partie la plus contraignante de la génération de la *CL12* a été la gestion d'énormes quantités de données à ingérer par les pipelines de traitement étant donné que nous avons utilisé les séries temporelles d'images Sentinel-2. Nos expériences montrent que l'utilisation de séries d'images Sentinel-2 seule n'améliore pas la cartographie annuelle de l'OCS des zones d'intérêt *T33PUL* et *T32NPL*, mais qu'elles peuvent être utiles pour des classes spécifiques (urbaines et forestières par exemple). En raison de la forte redondance entre les séries temporelles, il n'était pas utile de doubler le volume de données dans le cadre des travaux.

4.9 Conclusion

Plusieurs possibilités de la cartographie de l'OCS sur d'étendues réduites (tuiles) et grandes (bloc de tuiles Sentinel-2) ont été discutés dans ce chapitre. Le potentiel du *RF* pour les deux approches de classification - par tuile individuelle (*STR1*) et par bloc de tuiles (*STR2*) - en utilisant les jeux de données constitués de séries temporelles uniquement d'images optiques Sentinel-2 de niveau 2A (*L2A*) à hautes résolutions (*STR12* et *STR22*) et leurs différentes synthèses mensuelles de niveau 3A (*L3A*) *STR3* a été montré.

L'étude de la première stratégie (*STR1*) de la classification de l'OCS des zones d'intérêt *T33PUL* et *T32NPL* avec des séries temporelles d'images optiques Sentinel-2_2A (*STR12*) a premièrement été proposée, afin de comparer les performances des classifications mensuelles et annuelle (*STR12A,B*) produites pour chaque légende. En général, les résultats des classifications de séries temporelles d'images optiques Sentinel-2_2A des mois de mars, décembre et de l'année complète 2018 sont bons sur la zone d'intérêt *T33PUL* avec un nombre d'échantillons d'apprentissage suffisant par classe, un paramétrage optimal pour la légende à 5 classes. Sur la zone d'intérêt *T32NPL*, les résultats sont meilleurs dans les classifications du mois de février et de l'année complète 2018 pour la légende à 5 classes puis la classification de l'année complète 2018 pour les légendes à 9 et 12 classes. La classification de séries temporelles d'images optiques sur l'étendue d'une tuile Sentinel-2 est pertinente et importante pour gérer la grande quantité de données fournies par le satellite Sentinel-2. L'utilisation des trois légendes a aussi été intéressant, notamment avec de fortes précisions producteurs de la classification de l'année complète 2018 pour les légendes à 9 et 12 classes sur la zone d'intérêt *T32NPL*. Par conséquent, la fusion de classes d'OCS provenant de différentes *BDs* cartographiques ne peut pas mener à des résultats plus précis contrairement à la combinaison de plusieurs *BDs* qui peut conduire à des meilleurs résultats sur la zone d'intérêt *T32NPL*.

La procédure de classification a aussi été effectuée en appliquant la deuxième stratégie (*STR2*) de la thèse qui teste différents modèles de classification en fonction de la taille de la zone d'apprentissage, afin notamment d'évaluer l'influence de cette taille sur les performances de la classification en utilisant des séries temporelles d'images optiques Sentinel-2_2A (*STR22*). Plus précisément, les performances de la classification de l'année complète 2018 (*STR22B*) avec quatre modèles ont été évaluées pour chaque légende. Il en découle pour un nombre d'échantillons d'apprentissage suffisant par classe et un paramétrage optimal que les résultats de classification sont meilleurs sur la zone d'étude *ZONE1* avec le Modèle3 pour les légendes à 5 et 9 classes puis les Modèle1 et Modèle4 pour la légende à 12 classes. De manière régulière, les résultats sont meilleurs dans la classification de l'année complète 2018 des

classes d'OCS avec les modèles de plus grandes tailles de zone d'apprentissage tels que les Modèle3 et Modèle4 pour les trois légendes. Pour conclure, l'utilisation des modèles de grandes tailles de zone d'apprentissage sur une zone d'étude donnée permet d'améliorer la précision de la classification annuelle des classes difficilement représentées dans la classification de l'OCS sur l'étendue d'une zone d'intérêt au sein de cette zone d'étude.

L'étude du cas particulier du scénario (*STR2D*) des classifications mensuelles et annuelle de séries temporelles d'images optiques Sentinel-2_L2A (*STR22A,B*) de la zone d'étude *ZONE1* avec le Modèle4 où les échantillons d'apprentissage sont localisés sur cette zone d'étude entière a aussi été proposée, afin notamment d'évaluer les performances de classification lorsque la taille de la zone d'apprentissage est maximale et égale à celle de la zone test. Bien que le Modèle4 améliore significativement les performances et la qualité de la classification annuelle pour une taille maximale de zone d'apprentissage, la combinaison de *BDs* n'améliore pas la classification annuelle des classes RTE et BTM pour les légendes à 9 et 12 classes. De plus, la fusion des classes FRT; PRA et ARB de la légende à 9 classes en classe VGT de la légende à 5 classes n'est non plus un choix pertinent dans la mesure où le gain en précision de la classe VGT dans la classification annuelle avec le Modèle4 pour la légende à 5 classes sur la zone d'étude *ZONE1* est très faible comparé au sur-coût induit par l'augmentation de la quantité d'images Sentinel-2 et donc des vecteurs de variables et de la dimension du problème de classification à prendre en compte à la fois. Plus précisément, il était attendu que l'augmentation de la taille de la zone d'apprentissage aide l'algorithme de classification à mieux discriminer toutes les classes d'OCS de n'importe quelle légende en réduisant les confusions entre ces classes. Cependant, le *RF* permet déjà de ressortir de manière précise les classes en diminuant assez bien les confusions entre celles-ci dans la classification de l'OCS sur l'étendue de la zone d'intérêt représentée par la tuile *T33PUL* en exploitant les signatures spectrales des séries temporelles d'images optiques Sentinel-2_L2A. Toutefois, l'utilisation du Modèle4 améliore la précision de la classification annuelle de certaines classes d'OCS autrefois faible dans la classification de la zone d'intérêt *T33PUL*. C'est ainsi que les confusions diminuent grandement entre les classes des trois paires (VNC et RIV); (SFE et RTE) et (RIV et ARB) dans la classification annuelle de la zone d'étude *ZONE1* avec le Modèle4 pour la légende à 12 classes.

Le processus de classification a aussi été réalisé en exécutant la troisième stratégie (*STR3*) de la thèse qui traite des synthèses mensuelles de niveau *L3A* de séries temporelles d'images optiques Sentinel-2, générées pour différentes périodes, afin notamment d'évaluer l'influence des périodes de synthèse sur les performances de la classification en utilisant des synthèses de séries temporelles d'images optiques Sentinel-2_L3A. Plus précisément, les scénarios de classification (*STR3(PX)B*; $X \in \{45, 105, 165, 225\}$ et *STR3(P315)*) ont été expérimentés et les performances des classifications de l'année complète 2018 et des cinq synthèses *2018_P45*, *2018_P105*, *2018_P165*, *2018_P225* et *2018_P315* ont été évaluées pour chacune des trois légendes. Il en ressort pour un nombre d'échantillons d'apprentissage suffisant par classe et un paramétrage optimal que les résultats de classification sont meilleurs sur la zone d'intérêt *T33PUL* avec la série annuelle complète 2018 et la synthèse *2018_P315* pour la légende à 5 classes puis la série annuelle complète 2018 et les synthèses *2018_P45* et *2018_P105* pour la légende à 9 classes et enfin les synthèses *2018_P165* et *2018_P225* pour la légende à 12 classes. Sur la zone d'intérêt *T32NPL*, les résultats sont meilleurs dans les classifications avec la série annuelle complète 2018 et la synthèse *2018_P45* pour les légendes à 5 et 9 classes puis la série annuelle complète 2018 et la synthèse *2018_P105* pour la légende à 12 classes. Les performances de classification sont constamment meilleures avec les

synthèses. Par conséquent, il peut être intéressant de générer des synthèses mensuelles en effectuant la fusion précoce de séries temporelles d'images optiques Sentinel-2_L2A en amont du processus de classification. Les résultats du *RF* ont particulièrement montré des améliorations dans la classification de la synthèse 2018_P45 sur les zones d'intérêt. L'usage des trois légendes a permis de constater que les performances de cette classification augmentent avec le nombre de classes dans un paysage de zone test identique à celui de la zone d'entraînement, notamment avec de fortes précisions producteurs pour les légendes à 9 et 12 classes sur les zones d'intérêt. La fusion des différentes classes d'OCS issues de plusieurs *BDs* n'aide donc pas à améliorer la précision des classifications d'OCS en utilisant les synthèses de séries temporelles d'images optiques Sentinel-2_L2A sur chacune des deux zones d'intérêt.

L'étude du cas particulier des scénarios (*STR3(P45)A,B*) de classification de l'OCS des zones d'intérêt *T33PUL* et *T32NPL* avec des synthèses de périodes *P45* a également été proposée, afin notamment de comparer les meilleures performances de classification des différentes synthèses d'une période pour une légende donnée. Plus précisément, les performances des classifications des synthèses de périodes *P45* ont été évaluées pour chaque légende. L'étude révèle que les périodes de synthèse mensuelle influencent les performances de classification de l'OCS sur l'étendue d'une zone d'intérêt représentée par une tuile Sentinel-2. De manière générale, les résultats de classification sont meilleurs sur la zone d'intérêt *T33PUL* avec les synthèses septembre_P45 et 2018_P45 pour 5 classes puis juin_P45 et 2018_P45 pour 9 classes et enfin mars_P45 et septembre_P45 pour la légende à 12 classes. Sur la zone d'intérêt *T32NPL*, les résultats sont meilleurs dans la classification de la synthèse 2018_P45 seule pour les trois légendes. L'utilisation des trois légendes a aussi été intéressant, notamment avec de fortes précisions producteurs de la classification de la synthèse 2018_P45 lorsque le nombre de classes augmente sur les zones d'intérêt. Ainsi, la combinaison de différentes *BDs* pour constituer des légendes avec un grand nombre de classes peut contribuer à améliorer les performances de classification des synthèses mieux que la fusion des classes d'OCS au sein de ces légendes dans les zones d'intérêt. Toutefois, la combinaison de *BDs* constituant les légendes à 9 et 12 classes n'améliore pas les classifications des synthèses mensuelles de certaines classes d'OCS telles que les classes VNC; ZHU et SFE sur la zone d'intérêt *T32NPL*. Par contre, la fusion des classes FRT; PRA et ARB de la légende à 9 classes améliore la classification de la synthèse 2018_P45 pour la légende à 5 classes sur les deux zones d'intérêt. Ces faibles performances de classification des synthèses mensuelles de période *P45* pour la légende à 9 classes sont à l'origine des confusions notamment entre les classes SFE et ZHU sur la zone d'intérêt *T32NPL* alors que les performances sont bonnes dans la classification de la synthèse 2018_P45 des classes VNC et RIV pour la légende à 12 classes sur la zone *T32NPL*. De manière générale, les performances de classification de la synthèse 2018_P45 augmentent avec le nombre de classes lorsque le paysage de la zone à classer est identique à celui de la zone d'apprentissage.

Fusion de classifications de l'occupation du sol

"I can see nothing," said I, handing it back to my friend. "On the contrary, Watson, you can see everything. You fail, however, to reason from what you see. You are too timid in drawing your inferences."

– Arthur Conan Doyle (The Adventure of the Blue Carbuncle, 1892)

Sommaire

5.1	Fusion de classifications d'images optiques et radar	240
5.1.1	Introduction	240
5.1.2	Fusion de classifications en télédétection	241
5.2	Présentation des expérimentations	250
5.2.1	Évaluation	250
5.2.2	Problématiques et stratégies adoptées	250
5.2.3	Données satellitaires et de référence	251
5.2.4	Plan d'expérimentations	251
5.3	Apport de séries temporelles d'images Sentinel-1	251
5.3.1	Zone d'intérêt T33PUL (ZONE1, Nord)	252
5.3.2	Zone d'intérêt T32NPL (ZONE2, Ouest-Centre)	267
5.4	Fusion de classifications en alternative à la classification supervisée	284
5.4.1	Zone d'intérêt T33PUL (ZONE1, Nord)	285
5.4.2	Zone d'intérêt T32NPL (ZONE2, Ouest-Centre)	289
5.5	Conclusion	293

Résumé du chapitre :

Les trois approches de classification supervisée pour trois différentes légendes que nous avons mises en oeuvre et étudiées au chapitre précédent, sont ici traitées sous l'angle de la **fusion de niveau intermédiaire** qui consiste ici à fournir plusieurs dates et surtout plusieurs modalités (optique et radar) d'images à un classifieur au début du processus de classification et de la **fusion tardive** qui consiste à fusionner les différents résultats de classification (cartes d'OCS) en utilisant diverses méthodes de fusion exploitant des cartes de probabilité associées à ces résultats. Pour rappel, nous avons

préalablement effectué la **fusion précoce** lors de la génération des synthèses de niveau 3A (*L3A*) mais aussi lors du *gap-filling* (Section 3.2.4). Ainsi, un jeu de données est ici fourni au classifieur *RF* dans la chaîne de traitement *iota*² : la fusion de deux modalités complémentaires (a priori du moins) d'images optiques et radar Sentinel-1_*L1*/*-2_L2A* afin d'effectuer une fusion intermédiaire en vue du processus de classification. Ensuite, les résultats des classifications correspondantes sont fusionnés tardivement en utilisant diverses méthodes de fusion.

En effet, nous avons remarqué des problèmes dans les résultats des différentes classifications produites notamment que les structures linéaires des classifications d'OCS *e.g.* réseau routier ne sont pas bien discernables et les espaces verts sont hétérogènes et mal répartis. Ces remarques ont été corroborées par les différentes analyses statistiques effectuées. Du point de vue expérimental, les classifications de fusion intermédiaire d'images telles que menées dans les Sections 4.5, 4.6 et 4.7 peuvent être dégradées (comme dans notre cas), du fait de la présence de résidus de nuages non ou mal détectés sur certaines images. Pour cette raison, nous nous intéressons ici aux données radar provenant essentiellement du capteur Sentinel-1 et nous faisons de la fusion intermédiaire des données radar Sentinel-1 et des données optiques Sentinel-2 dans le but de réduire ces résidus de nuages. Par ailleurs, nous avons constaté que le traitement de la série annuelle complète s'effectue pendant une longue durée au risque d'interruption brusque pour cause de coupure d'électricité. Ainsi, nous faisons en plus dans ce chapitre de la fusion tardive des classifications préalablement produites à l'idée de savoir si cette fusion permet de passer outre ces problèmes.

Ainsi, ce chapitre s'intéresse davantage aux différentes méthodes de fusion (tardive) de classifications d'OCS. Dans un premier temps, la fusion intermédiaire et les caractéristiques des données de télédétection dont dépendent les différents niveaux de fusion sont introduites et les méthodes de fusion (tardive) de classifications de l'état-de-l'art ainsi que les limites de ces méthodes sont abordées. L'originalité repose sur l'application des méthodes de fusion (tardive) aux classifications supervisées de la fusion de deux modalités complémentaires (a priori du moins) d'images optiques et radar Sentinel-1_*L1*/*-2_L2A* dans la chaîne de traitement *iota*². Dans un deuxième temps, les expérimentations des deux études de : 1) l'apport de séries d'images Sentinel-1 par rapport aux séries temporelles d'images Sentinel-2 seules sur l'étendue d'une tuile et 2) la fusion des résultats de classifications comme une alternative à la classification supervisée directe, sont présentées. Ensuite, les résultats de ces études sont respectivement détaillés et analysés en troisième et quatrième temps. Enfin, les conclusions sont tirées.

5.1 Fusion de classifications d'images optiques et radar

5.1.1 Introduction

Les dernières années ont vu l'émergence d'une grande variété de nouveaux capteurs avec diverses caractéristiques telles que nous avons présenté au Chapitre 2. La possibilité de collecter différents types d'observations sur la même zone a considérablement augmenté : la télédétection peut désormais être considérée comme génériquement multimodale (GOMEZ-CHOVA et al., 2015). Ces capteurs concernent différentes modalités : radar, lidar ou optique. Ils peuvent être aéroportés ou satellitaires. Même pour une même modalité, ils peuvent présenter des caractéristiques très différentes. Par exemple, les capteurs optiques présentent une large gamme de configurations spectrales (nombre, position et largeur de bandes spectrales), de couvertures et résolutions spatiales, de temps de revisite. Par

conséquent, combiner des données de télédétection avec différentes caractéristiques est un problème de télédétection standard largement étudié dans la littérature (CHAVEZ et al., 1991). L'objectif final consiste à fusionner des informations multi-capteurs afin de combiner les avantages respectifs de chaque capteur. Des observations complémentaires peuvent ainsi être exploiter pour des fins de cartographie de l'OCS.

5.1.2 Fusion de classifications en télédétection

L'objectif de cette section est de présenter les différents concepts généraux de la fusion de données dans le domaine de la télédétection et de l'imagerie ayant pour but de produire des cartes d'OCS. La fusion de données est un terme général n'ayant aucun cadre mathématique précis. Un tel processus dépend de la nature même des données, du résultat souhaité en fonction du type de fusion utilisé, des limites et du choix d'une stratégie dépendant des informations initiales ou encore des règles de fusion à respecter. Dans un premier temps, les caractéristiques des données de télédétection sont rappelées. Dans un deuxième temps, la fusion de données est expliquée. Dans un troisième temps, les limites des différents niveaux de fusion sont présentées et le choix d'une stratégie est discuté. Finalement, une dernière partie est dédiée aux règles de fusion des données en télédétection.

5.1.2.1 Caractéristiques des données de télédétection

Les propriétés essentielles d'identification et de reconnaissance de l'objet sont fournies par son contexte. En effet, un objet ou plus précisément ici un pixel n'est parfaitement défini, qu'une fois replacé dans son contexte (PIECZYNSKI, 1989 ; SCHISTAD, TAXT et JAIN, 1996a). Le contexte est un ensemble d'attributs permettant de définir et de caractériser l'objet d'une manière précise et complète. La Figure 5.1 illustre les trois attributs principalement définis : 1) l'attribut spectral, 2) l'attribut spatial, et 3) l'attribut temporel.

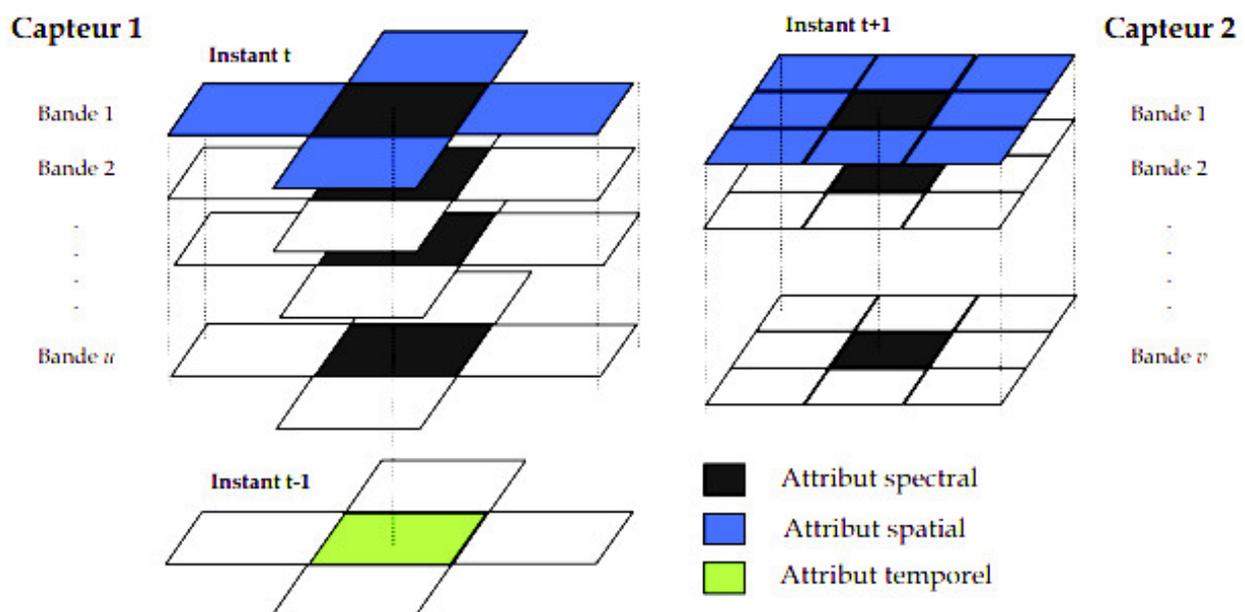


FIG. 5.1 – Contexte de l'objet.

- L'**attribut spectral** est lié à la résolution spectrale de l'image et fait référence à la largeur de la bande électromagnétique dans laquelle opère le capteur, et au nombre de capteurs multispectraux embarqués.
- L'**attribut spatial** est lié d'une part à la résolution spatiale de l'image représentant le plus petit détail au sol perceptible par le capteur, et d'autre part à la structure spatiale du voisinage du pixel dans l'image.
- L'**attribut temporel** est lié soit, à la résolution temporelle du capteur d'acquisition définie par son cycle de passage au-dessus du même point, soit à la résolution temporelle d'un ensemble de satellites fonctionnant en constellation et qui est définie par le cycle de passage de chaque satellite au-dessus du même point sur un court intervalle de temps.

5.1.2.2 Fusion de données

Une définition générale de la fusion de données a été présentée par (WALD, 1999) : *la fusion de données constitue un cadre formel dans lequel s'expriment les données provenant de sources diverses ; elle vise à l'obtention d'informations de plus grande qualité ; la définition de « plus grande qualité » dépend de l'application.* Par ailleurs, (BLOCH, 2003) propose une autre définition : *la fusion d'informations consiste à combiner des informations issues de plusieurs sources afin d'améliorer la prise de décision.* Cette définition va plus loin que la première, jusqu'à la décision. Ainsi, en combinant les trois attributs (spectral, spatial et temporel), nous pouvons définir plusieurs types de fusion dont le but est l'amélioration de prise de décision concernant la nature thématique (la classe) de ce pixel. Ces types de fusion sont communément désignés par le terme « **fusion multisource** » (SCHISTAD, 1996b ; WALD, 1998 ; WALD, 1999 ; VAN et FRASER, 1999) ou le terme plus général de « **fusion contextuelle** » (VAN et FRASER, 1994 ; SCHISTAD, TAXT et JAIN, 1996a ; SCHISTAD, 1999 ; SOLAIMAN, PIERCE et ULABY, 1999). La fusion de sources de données hétérogènes a été largement étudiée dans le domaine de la télédétection comme par exemple, (POHL et GENDEREN, 1998 ; LIAO, CHANUSSOT et PHILIPS, 2018). La fusion peut être réalisée à différents niveaux (Figure 5.2, avec trois images issues de trois sources notées S_1 , S_2 et S_3 (MANGOLINI, 1994)) :

1. Niveau d'observation : fusion de pixels (fusion précoce),
2. Niveau d'attribut : fusion d'attributs (fusion précoce),
3. Niveau de décision : fusion de décisions (fusion tardive).

On parle de fusion « bas niveau » lorsque les données combinées sont proches des paramètres physiques mesurés et de « haut niveau » si l'on traite des attributs sémantiques extraits de ces mesures.

5.1.2.2.1 Fusion de pixels La fusion peut s'opérer au niveau de l'observation c'est-à-dire par l'analyse conjointe directe des valeurs de pixels (avec ou sans procédures d'étalonnage) de l'image qui constituent les mesures les plus proches de l'observation physique de l'objet. A cet effet, l'affinage panchromatique ou *pan-sharpening* est une technique bien connue qui intègre les détails géométriques d'une image à haute résolution (*HR*) spatiale et les informations de couleur d'une image multispectrale (ou hyperspectrale) à faible résolution spatiale pour produire une image multispectrale (ou hyperspectrale) à *HR* spatiale. D'autres algorithmes de fusion ont été proposés pour fusionner des images multispectrales (ou hyperspectrales) et panchromatiques (mais aussi multispectrales et hyperspectrales) afin de combiner des caractéristiques complémentaires en termes de résolutions spatiale et spectrale (YANG, WANG et JIAO, 2012 ; LONCAN et al., 2015). Une revue de la littérature sur ces

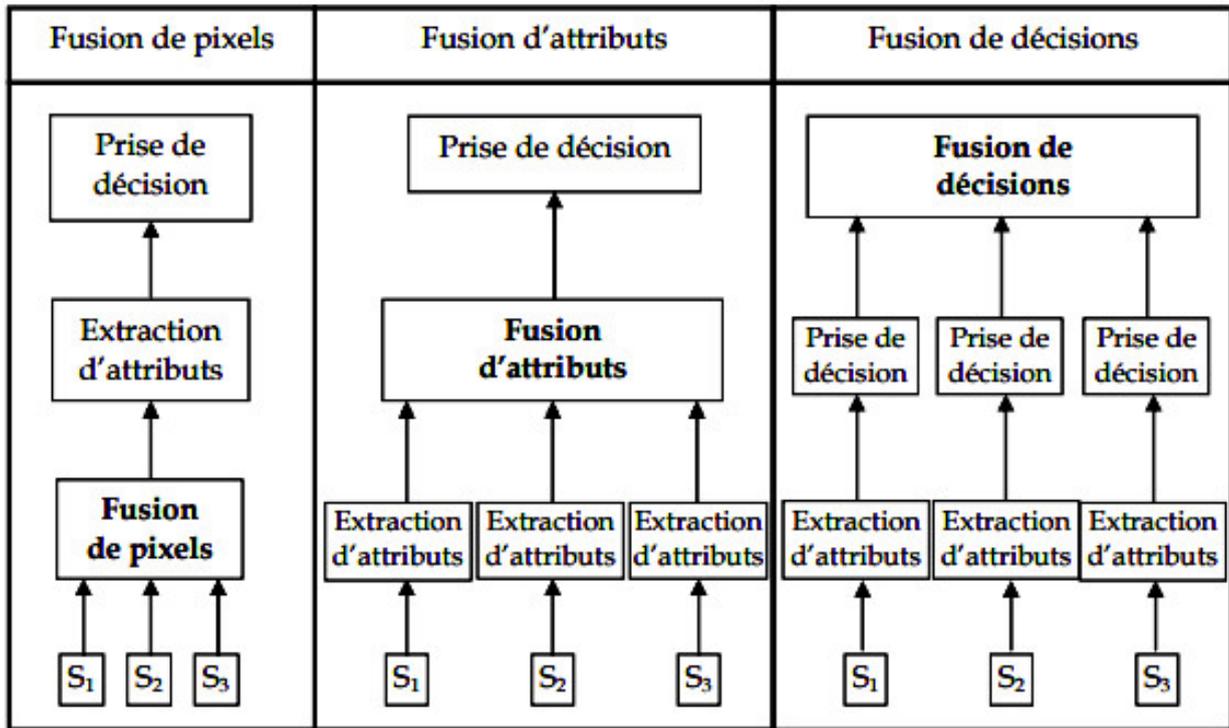


FIG. 5.2 – Niveaux de la fusion de données, illustrés avec trois sources S .

méthodes peut être trouvée dans (LONCAN et al., 2015). Éventuellement, la super-résolution est une autre approche reposant sur la fusion de pixels de plusieurs capteurs (YUAN, ZHENG et LU, 2017).

5.1.2.2.2 Fusion d'attributs La fusion peut également s'opérer sur des primitives ou des caractéristiques extraites à partir de chaque image. Ces primitives peuvent être des contours, des régions, des textures ou des composantes fréquentielles. Les primitives (indices spectraux, basées sur la texture etc.) sont calculées séparément pour chaque source ou pour des couples de sources de données avant d'être introduites dans le même classifieur à l'aide d'un unique ensemble de primitives (GRESSIN et al., 2015). Des exemples de travaux de télédétection impliquant la fusion au niveau des attributs peuvent être trouvés dans (FAUVEL et al., 2007; XIA, MING et IWASAKI, 2018). Par exemple, (WEGNER et al., 2011) a proposé un modèle graphique probabiliste par champ aléatoire conditionnel (*Conditional Random Field (CRF)*) pour la détection de bâtiments à l'aide de primitives d'*InSAR* et d'ortho-image. (DECHESNE et al., 2017) a fusionné les primitives d'images Lidar et optiques aériennes pour l'extraction des peuplements forestiers : l'approche proposée implique plusieurs étapes (segmentation, classification et régularisation) et la fusion est opérée à chacune de ces étapes. Plus récemment, des réseaux neuronaux à convolution profonde ont été utilisés pour effectuer la fusion de données au niveau de l'attribut (AUDEBERT, SAUX et LEFÈVRE, 2017). (XIA, MING et IWASAKI, 2018) a appliqué par exemple des forêts profondes aux primitives d'imageries hyperspectrale et Lidar. Une revue de la littérature détaillée peut être trouvée dans (ZHU et al., 2017). Plusieurs jeux de données et défis ont été publiés au cours des dernières décennies notamment sous l'égide de la société *IEEE GRSS* (BERGER et al., 2013; YOKOYA et al., 2018).

5.1.2.2.3 Fusion de décisions La fusion peut enfin s'opérer en combinant les décisions tardives des traitements effectués sur chaque source pour obtenir une solution globale optimale. La fusion est

opérée après classification sans tenir compte des caractéristiques internes des traitements monosources : les sorties de plusieurs classifieurs indépendants sont combinées. De tels résultats de classification peuvent être soit des cartes de labels ou des cartes de probabilité d'appartenance aux différentes classes en présence. Diverses méthodes de fusion de décisions tardives ont été proposées. La plupart d'entre elles peuvent être scindées selon différentes catégories telles que les règles de consensus (vote majoritaire), les approches probabilistes (fusion bayésienne), les approches de crédibilité (ou d'évidentiel) et les approches possibilistes.

Les approches de fusion de décisions probabiliste, évidentielle et crédibiliste sont génériques et peuvent être appliquées à différents problèmes de fusion. Ils ne nécessitent que des mesures d'appartenance (probabilités ou masses de croyance selon l'approche) pour chaque source et pour chaque classe, ou tout au moins une mesure de confiance pour chaque source.

Les méthodes possibilistes utilisent des règles de fusion basées sur la logique floue (DUBOIS et PRADE, 1992; ZADEH, 1965). Ils nécessitent de définir des poids (PAL et BEZDEK, 1994) dans le but de mieux gérer l'incertitude des différentes sources. De telles approches génériques ont été appliquées aux données de télédétection (FAUVEL, CHANUSSOT et BENEDIKTSSON, 2006).

Les approches évidentielles sont une généralisation des approches probabilistes. Elles intègrent la règle de fusion bien connue de Dempster-Shafer (SHAFER, 1976). En télédétection, cette règle a souvent été utilisée pour fusionner des classifications ou des résultats de détection d'alarme. Par exemple, (POULAIN et al., 2011; TIAN et DEZERT, 2019) ont appliqué la règle de Dempster-Shafer pour combiner différents détecteurs de bâtiments supervisés basés sur différentes modalités de télédétection (optique, Lidar, radar). Cette règle a également été utilisée par (CHAVEZ-GARCIA et AYCARD, 2016) pour la fusion de différents détecteurs d'obstacles routiers dans le contexte du développement de véhicules intelligents. (LEFEBVRE, SANNIER et CORPETTI, 2016) ont utilisé la règle de Dempster-Shafer pour la fusion d'empreintes urbaines détectées à différentes dates à partir d'images d'archives satellitaires. (HÉGARAT-MASCLE et SELTZ, 2004; HÉGARAT-MASCLE et al., 2006) ont appliqué cette règle pour détecter des changements dans un cadre de classification non supervisée.

Une autre règle de fusion évidentielle est la règle de Yager. Elle a été appliquée par (OH et KANG, 2017) pour combiner différents détecteurs d'obstacles routiers pour la navigation de véhicules. D'autres règles de fusion évidentielles ont été proposées plus récemment : la règle de Dezert-Smarandache peut être mentionnée (DEZERT, 2013). D'autres nouvelles règles ont également été proposées par (MARTIN et OSSWALD, 2007b; MARTIN, 2009) : elles étendent les règles de Dempster-Shafer afin d'obtenir une meilleure gestion de conflits entre sources. Bien qu'efficace dans certains cas, Dempster-Shafer et les variantes précédentes restent avant tout un cadre théorique complexe qui ne s'applique pas toujours facilement lorsqu'il s'agit de gérer des données multiples et hétérogènes.

Un autre problème important consiste à définir l'entrée des différentes règles de fusion. Différentes situations peuvent être prises en compte selon qu'une mesure de confiance globale est affectée pour chaque source, ou inversement que des probabilités à posteriori de classes pour une source donnée sont directement disponibles pour chaque pixel (directement fournies par le classifieur initial). Dans la première situation, les mesures de confiance globales affectées à chaque source sont calculées à partir des matrices de confusion (en effet, une matrice de confusion fournit la probabilité d'un objet étiqueté classe *A* par une source, d'appartenir en fait à la classe *B*). Des données de validation sont donc nécessaires pour calculer ces poids. De plus, pour les méthodes évidentielles et en particulier

les méthodes de type Dempster-Shafer, des classes d'incertitude (c'est-à-dire des unions de classes d'origine) peuvent être définies. Les masses de croyance associées à ces classes doivent être calculées. Si une confiance globale est associée à une source, certaines solutions ont été proposées. Par exemple, nous avons la méthode d'Appriou (APPRIOU, 1991), ou plus récemment la méthode présentée dans (CAO, LEE et KWON, 2018; LEE et al., 2016). Si une mesure d'appartenance est affectée à chaque pixel pour chaque source et pour chaque classe, il est également possible de dériver des masses de croyance pour ces classes d'incertitude (union). Par exemple, (LEFEBVRE, SANNIER et CORPETTI, 2016) proposent une manière alternative d'intégrer ces deux types d'informations.

Enfin, la dernière catégorie des approches de fusion de décisions consiste en un **apprentissage supervisé**. Elles apprennent automatiquement à partir d'exemples d'entraînement la meilleure façon de fusionner les différentes sources. Les probabilités de classe de chaque source sont concaténées et considérées comme des vecteurs de primitives. Ces vecteurs de primitives sont ensuite fournis en entrée d'un classifieur qui est entraîné pour effectuer la meilleure fusion possible. Cette stratégie peut être considérée comme étant à la frontière entre la fusion de décisions et la fusion des attributs (les classifieurs préalablement appliqués à chaque source peuvent alors être considérés comme une sorte de générateurs de primitives, et ensuite considérés comme appelée une classification automatique de contexte (TU et BAI, 2010)). De telles approches ont été utilisées avec différents classifieurs : *Random Forest (RF)* (WENDL et al., 2018; KNAUER et SEIFFERT, 2013), *Adaboost* (KNAUER et SEIFFERT, 2013), *Support Vector Machines (SVM)* (WASKE et BENEDIKTSSON, 2007a; CEAMANOS et al., 2010) et *CNN* (STOCKER et LE-BRIS, 2020). Ces méthodes pour l'apprentissage supervisé permettent d'avoir de bons résultats; mais nécessitent une quantité suffisante de données d'entraînement pour modéliser les classes et éviter le sur-ajustement (surtout pour l'apprentissage profond).

On peut aussi préciser que la plupart des méthodes de fusion mentionnées dans cette section génèrent des mesures pour évaluer le conflit entre deux sources.

Les approches par décisions ont souvent été appliquées aux problèmes de fusion en télédétection (BENEDIKTSSON et KANELLOPOULOS, 1999; MOHAMMAD-DJAFARI, 2003; FAUVEL, CHANUSSOT et BENEDIKTSSON, 2006; WASKE et BENEDIKTSSON, 2007a; LE-BRIS et BOLDO, 2008; PAISITKRIANGKRAI et al., 2015). Les méthodes de fusion opérant au niveau de la décision peuvent être appliquées dans deux situations selon qu'elles essaient de fusionner plusieurs classifieurs appliqués soit à la même source de données ou à de multiples sources. Par exemple, (BENEDIKTSSON et KANELLOPOULOS, 1999) ont combiné le classifieur neuronal et de maximum de vraisemblance statistique en utilisant plusieurs règles de la théorie du consensus (vote majoritaire, accord complet) pour classifier des images multispectrales et hyperspectrales. (LE-BRIS et BOLDO, 2008; LE-BRIS et CHEHATA, 2011) ont fusionné des probabilités à posteriori des classifications d'images optiques par maximum de vraisemblance avec des informations à priori sur des classes provenant respectivement des *Modèles Numériques de Terrain* ou des *Modèles Numériques de Surface*, de même que des informations provenant des *BDs d'OCS* existantes. (JEON, 1999) a étudié la fusion d'images multi-temporelles de cartographie thématique, en utilisant des méthodes basées sur la fusion de décisions plus précisément la vraisemblance conjointe et la fusion majoritaire pondérée. Une caractérisation de l'organisation spatiale des éléments d'image SAR est étudiée par (TUPIN, BLOCH et MAITRE, 1999) en fusionnant les réponses de multiples détecteurs bas niveau appliqués à la même image dans un schéma Dempster-Shafer. (FAUVEL, CHANUSSOT et BENEDIKTSSON, 2006) ont étudié l'utilisation des règles de décision floues pour combiner les résultats de classification d'un réseau de neurones et un classifieur flou sur une image IKONOS.

(PAISITKRIANGKRAI et al., 2015) ont combiné des classifieurs de réseaux de neurones convolutifs et de forêts aléatoires.

5.1.2.3 Limites et choix d'une stratégie

Cet état-de-l'art a répertorié trois différents niveaux de fusion. Le premier niveau s'opère directement sur les pixels de l'image, le deuxième exploite les primitives ou les caractéristiques extraites à partir de chaque image, et le troisième exploite sur les traitements préalablement effectués sur chaque source.

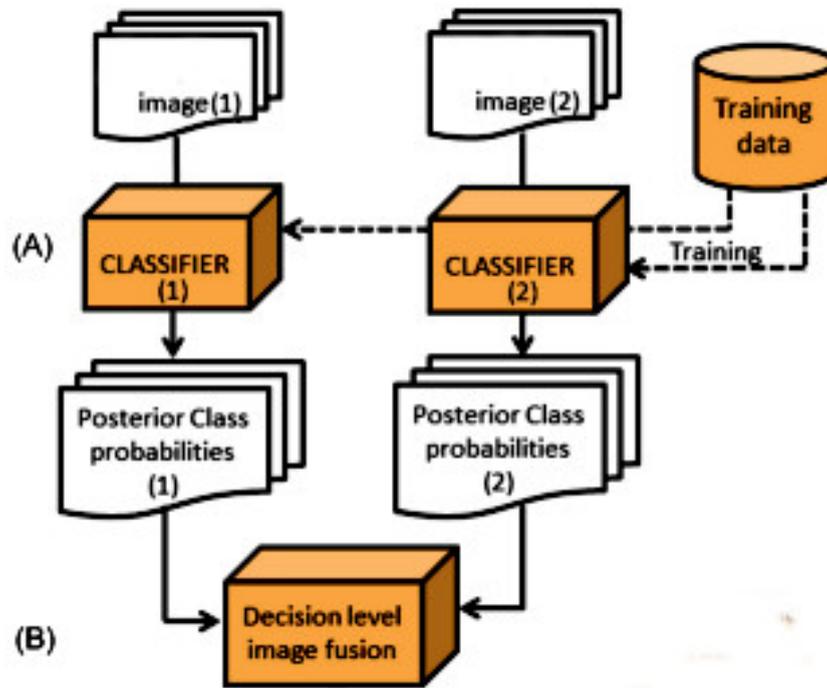
La fusion de pixels au niveau de l'observation est plutôt limitée à des situations spécifiques où elle a une réelle signification physique comme par exemple des images hyperspectrales et multispectrales acquises simultanément. Elle n'est donc pas adaptée à notre problème.

La fusion au niveau de l'observation ou au niveau de la décision est plus générique et également éligible au problème de fusion qui se pose dans cette thèse. Cependant deux problèmes majeurs demeurent : 1) pour les deux niveaux de fusion, l'échelle spatiale d'analyse et par conséquent, le processus d'interpolation, et 2) pour les approches basées sur les primitives, la capacité à correctement gérer les différentes sources de données dans le processus de décision. En cas de déséquilibre d'ensembles de primitives, des techniques supervisées telles que les *RF* qui intègre un mécanisme interne de sélection d'attributs ou les *SVM*, pourraient préférer la source de données générant le plus grand nombre d'attributs même avec des stratégies de sélection de primitives. Ainsi, le processus ne bénéficiera pas pleinement des avantages de tous les jeux de données.

En conséquence, la **stratégie de fusion de décisions est adoptée dans ce chapitre et appliquée sur deux jeux de données** : 1) la fusion des modalités complémentaires d'images optiques et radar Sentinel-1_L1/-2_L2A, et 2) la fusion de synthèses mensuelles de niveau 3A d'images optiques avec les images radar Sentinel-1_L1/-2_L3A. En effet, contrairement aux méthodes de fusion intermédiaire, elle permet de traiter dans un premier temps chaque source de données d'entrée indépendamment. De plus, elle permet d'utiliser des résultats déjà existants. En outre, elle peut être utilisée sans aucune information sur les données d'entraînement (vérité terrain), contrairement aux méthodes de fusion de données de niveau intermédiaire uniquement dans cette dernière situation. Dans le cadre des travaux de recherche, onze méthodes de fusion de décisions sont appliquées indépendamment à chacun des deux précédents jeux de données.

Dans notre problématique, les onze méthodes utilisées ici s'appuie sur la notion de complémentarité entre capteurs. Ainsi, pour bénéficier des données à faible résolution spatiale (mais améliorées spectralement ou temporellement) et des données multi-temporelles à haute résolution (*HR*) spatiale, un cadre des travaux de fusion de décisions est proposé. Il consiste en deux principales étapes *A* et *B* présentées à la Figure 5.3 :

- (A) **Classification de chaque source originale et génération des probabilités postérieures de classe** : dans un premier temps, les deux sources de données d'entrée sont étiquetées automatiquement, indépendamment par des processus spécifiques adaptés. A la fin une carte de probabilité postérieure de classe est générée pour chacune d'elles. Ici, les prédictions ont déjà été calculées et sont considérées comme étant accordées.



Source : (LE-BRIS et al., 2019)

FIG. 5.3 – Cadre des travaux génériques proposés.

(B) **Fusion par pixel des probabilités postérieures au niveau de la décision** : une fusion de décision par pixel est appliquée à ces cartes afin de les combiner en une plus précise décision à la résolution spatiale la plus élevée. Des règles de fusion différentes sont considérées. Cette étape vise à traiter les incertitudes sémantiques entre les sources. Une mesure de conflit entre sources peut également être générée à cette étape telle que détaillée dans la Section 5.1.2.

5.1.2.4 Règles de fusion

5.1.2.4.1 Règles floues La première approche de fusion testée est basée sur des règles floues (ZADEH, 1965). La théorie des règles floues stipule qu'un ensemble flou A dans un ensemble de référence de classes \mathcal{L} est un ensemble de couples ordonnés :

$$A = [(c, P_A^{(c)}(x) | c \in \mathcal{L})], \quad (5.1)$$

où la probabilité d'appartenance de A à \mathcal{P} est donnée par $P_A^{(c)} : \mathcal{L} \rightarrow [0, 1]$. La mesure du conflit $(1 - K)$ entre deux sources est donné par (DUBOIS et PRADE, 1997) :

$$K = \sup_{c \in \mathcal{L}} \min(P_A^{(c)}(x), P_B^{(c)}(x)). \quad (5.2)$$

Dans les travaux d'expérimentations qui suivent, toutes les règles floues ont été testées en entrée en utilisant les probabilités pondérées par la mesure ponctuelle et les formules sont ici données pour deux sources, mais nous en manipulons davantage.

Les règles de fusion suivantes basées sur la logique floue ont été considérées :

1. **Règle des minimums (min)** correspondant à l'intersection de deux ensembles flous P_A et P_B , donnée par le minimum de leurs probabilités d'appartenance (comportement conjonctif) :

$$\forall c \in \mathcal{L} (P_A \cap P_B)^{(c)}(x) = P_{fusion}^{(c)}(x) = \min(P_A^{(c)}(x), P_B^{(c)}(x)). \quad (5.3)$$

2. **Règle des maximums (max)** correspondant plutôt à l'union entre les deux ensembles flous P_A et P_B , donnée par la maximum de leurs probabilités d'appartenance (comportement disjonctif) :

$$\forall c \in \mathcal{L} (P_A \cup P_B)^{(c)}(x) = P_{fusion}^{(c)}(x) = \max(P_A^{(c)}(x), P_B^{(c)}(x)). \quad (5.4)$$

5.1.2.4.2 Combinaison bayésienne et vote majoritaire Une approche simple consiste à additionner ou à multiplier les probabilités d'appartenance à la classe d'entrée comme une somme bayésienne (\sim vote majoritaire) ou un produit (BLOCH, 1996) :

$$P_{fusion_somme}^{(c)}(x) = P_A^{(c)}(x) + P_B^{(c)}(x), \quad (5.5)$$

$$P_{fusion_produit}^{(c)}(x) = P_A^{(c)}(x) \times P_B^{(c)}(x). \quad (5.6)$$

Ces règles seront respectivement appelées **somme bayésienne** et **produit bayésien**.

5.1.2.4.3 Règles fondées sur la marge du classifieur L'objectif de ces règles est de prendre en compte la confiance mesurée par la marge de classification de chaque source. La marge de classification est définie pour chaque pixel x et chaque source s comme la différence entre les deux probabilités de classe les plus élevées :

$$marge^{(s)}(x) = P_s^{(C_{best1})}(x) - P_s^{(C_{best2})}(x), \quad (5.7)$$

avec $C_{best1}^{(s)}(x) = \operatorname{argmax}_{c \in \mathcal{L}} P_s^{(c)}(x)$ et $C_{best2}^{(s)}(x) = \operatorname{argmax}_{c \in \mathcal{L} \setminus [C_{best1}^{(s)}(x)]} P_s^{(c)}(x)$.

La fusion peut alors s'effectuer en privilégiant pour chaque pixel la source la plus confiante c'est-à-dire celle avec la marge la plus élevée. Cette règle de fusion appelée **marge-Max** sélectionne pour chaque pixel, la source pour laquelle la marge entre les deux probabilités les plus élevées est la plus élevée, avec les sources $S = A, B$ et les classes $\mathcal{L} = \{c_i\}_{1 \leq i \leq n}$:

$$\forall x, \forall c \in \mathcal{L} P_{fusion}^{(c)}(x) = P_{S_{best}}^{(c)}(x), \quad (5.8)$$

où $S_{best} = \operatorname{argmax}_{S \in \mathcal{L}} marge^{(s)}(x)$.

L'information de confiance du classifieur fournie par la marge peut également être utilisée pour pondérer les probabilités de classe de chaque source dans la somme bayésienne (somme bayésienne pondérée de la marge) et le produit bayésien (produit bayésien pondéré de la marge) :

$$P_{fusion_somme}^{(c)}(x) = \frac{P_A^{(c)}(x).marge^{(A)}(x) + P_B^{(c)}(x).marge^{(B)}(x)}{marge^{(A)}(x) + marge^{(B)}(x)}, \quad (5.9)$$

$$P_{fusion_produit}^{(c)}(x) = (P_A^{(c)}(x))^{\frac{marge^{(A)}(x)}{marge^{(A)}(x)+marge^{(B)}(x)}} \times (P_B^{(c)}(x))^{\frac{marge^{(B)}(x)}{marge^{(A)}(x)+marge^{(B)}(x)}}. \quad (5.10)$$

5.1.2.4.4 Théorie de l'évidence de Dempster-Shafer Selon le formalisme de Dempster-Shafer (*DS*), une information d'une source s pour une classe c peut être donnée comme une fonction de masse $m_c \mid m_c \in [0, 1]$ (SHAFER, 1976). La règle de la théorie de l'évidence de Dempster-Shafer suppose des classes simples $c \in \mathcal{L}$ de même que des classes composées et limitées à deux classes simples au

plus (OUERGHEMMI et al., 2017). Les masses associées à chaque classe simple sont directement les probabilités d'appartenance à la classe :

$$m_s^{(c)}(x) = P_s^{(x)}. \quad (5.11)$$

Pour les classes mixtes, $\forall c_1, c_2 \in \mathcal{L}, \forall \text{pixel } x \text{ et } \forall s \in S$, seule la version DSV_2 a été testée (confère résultats très proches avec DSV_1) :

$$\begin{aligned} m_s^{(c_1 \cup c_2)}(x) &= (P_s^{(c_1)}(x) + P_s^{(c_2)}(x)) \\ &\times (1 - \max(P_s^{(c_1)}(x), P_s^{(c_2)}(x))) \\ &+ \min(P_s^{(c_1)}(x), P_s^{(c_2)}(x)), \end{aligned} \quad (5.12)$$

$$\begin{aligned} m_s^{(c_1 \cup c_2)}(x) &= \frac{1}{2}(P_s^{(c_1)}(x) + P_s^{(c_2)}(x)) \\ &\times (1 - \max(P_s^{(c_1)}(x), P_s^{(c_2)}(x))) \\ &+ \min(P_s^{(c_1)}(x), P_s^{(c_2)}(x)). \end{aligned} \quad (5.13)$$

Ceci conduit à une masse $m_s^{(c_1 \cup c_2)}(x) \in [0, 1]$ étant égal 1 si $P_s^{(c_1)} = 0, P_s^{(c_2)} = 1$ ou $P_s^{(c_2)} = 0, P_s^{(c_1)} = 1$. Dans les deux versions, toutes les masses sont normalisées telles que $\sum_{c \in \mathcal{L}}^{(s)} m_c^{(s)}(x) = 1$.

La règle de fusion est pour la mesure de conflit suivante entre deux sources A et B :

$$K(x) = \sum_{\substack{c, d \in \mathcal{L}' \\ c \cap d \neq \emptyset}}^{(s)} m_A^{(c)}(x) m_B^{(d)}(x), \quad (5.14)$$

$c, d \in \mathcal{L}$ étant des classes mélangées avec $c \cap d = \emptyset$. La fusion est calculée par :

$$m_{fusion}^{(c)}(x) = \frac{1}{1 - K(x)} \sum_{\substack{c_1, c_2 \in \mathcal{L}' \\ c_1 \cap c_2 = c}}^{(s)} m_A^{(c_1)}(x) m_B^{(c_2)}(x). \quad (5.15)$$

5.1.2.4.5 Règles de fusion supervisée : approches pour l'apprentissage En plus des règles de fusion standard précédentes, des méthodes supervisées basées sur l'apprentissage ont également été testé (WASKE et BENEDIKTSSON, 2007a; CEAMANOS et al., 2010; AUDEBERT, SAUX et LEFÈVRE, 2017). Ces méthodes consistent à apprendre comment fusionner au mieux deux sources de données (basées sur une vérité de terrain). Un classifieur est entraîné à étiqueter les vecteurs de primitives correspondant à la concaténation des mesures d'appartenance à une classe de deux sources. Ainsi, une telle stratégie peut être considéré à la limite entre la fusion de décisions et la fusion d'attributs (des classifieurs appliqués indépendamment de chaque source peuvent alors être considérés comme une sorte de générateurs de primitives) similairement aux approches d'*auto-context*. Un inconvénient vient du fait qu'elles nécessitent de disposer de données de référence.

Dans les expériences suivantes, trois classifieurs ont été utilisés pour la fusion supervisée : 1) l'algorithme des forêts aléatoires (*RF*) (BREIMAN, 2001), 2) l'algorithme du SVM linéaire (*SVM-linéaire*), et 3) l'algorithme du SVM à noyau gaussien K_{RBF} - *Radial Basis Function (RBF)* (*SVM-RBF*).

5.2 Présentation des expérimentations

5.2.1 Évaluation

Les méthodes de fusion ci-dessus ont été appliquées sur différents jeux de données satellitaires multisources multitemporelles. On vise à résoudre entre autres les problèmes liés à la présence de résidus de nuages non ou mal détectés sur certaines images au cours des différentes classifications produites au Chapitre 4. Les nuages et leurs ombres diminuent en effet les performances. Par conséquent, l'évaluation quantitative et qualitative et une étude comparative des différentes méthodes de fusion sont réalisées en se fondant uniquement sur la première approche adoptée pour la classification supervisée en présence d'images radar complémentaires aux images optiques.

5.2.2 Problématiques et stratégies adoptées

5.2.2.1 Problématiques

Faisant suite aux études menées au Chapitre 4, les problématiques traitées, ici, portent uniquement sur l'étude d'impact relative à la **stratégie d'apprentissage (APP)** du classifieur en utilisant des jeux de données comprenant cette fois-ci des images radar Sentinel-1. Une seule étude d'impact relative à la stratégie d'apprentissage du classifieur à savoir l'**auto-entraînement (APP1)** est effectuée afin de savoir si les résultats sont améliorés en entraînant sur une tuile pour appliquer ensuite le modèle obtenu sur cette même tuile en présence d'images Sentinel-1. De surcroît, les deux études d'impact relatives aux jeux de données à savoir l'**influence de la nomenclature (JDD1)** et l'**influence de la dimension temporelle (JDD2)** décrites dans le Chapitre 4 sont également réalisées.

5.2.2.2 Stratégies adoptées

La **première stratégie** adoptée au Chapitre 4 est utilisée, ici, **en présence d'images radar uniquement sur les deux zones d'intérêt T33PUL et T32NPL** pour répondre aux problématiques mentionnées précédemment.

La **première stratégie (STR1)** est utilisée avec le jeu de données constitué de séries temporelles à la fois d'**images optiques Sentinel-2 de niveau 2A et radar Sentinel-1 de niveau 1A** (Sentinel-1_L1/-2_L2A). Comme dans le Chapitre 4, des classifications sont calculées sur deux périodes (mensuelle et annuelle) de classification c'est-à-dire :

- pour **chacun des 12 mois** de janvier à décembre (**STR12A**),
- pour l'ensemble des 12 mois constituant l'**année complète 2018 (STR12B)**.

En fonction des légendes utilisées, l'**apport des images Sentinel-1 par rapport aux images Sentinel-2 seules** est analysé en testant l'auto-entraînement sur l'étendue de chaque zone d'intérêt (première stratégie) et la **fusion tardive des résultats de classifications comme une alternative à la classification supervisée directe** est également analysée dans chaque zone d'intérêt. Ces deux questions majeures sont ici étudiées en présence d'images multi-temporelles radar Sentinel-1.

Dix méthodes de fusion tardive sont distinctement appliquées aux différentes classifications mensuelles et de synthèses mensuelles d'images Sentinel-2 en complémentarité avec les images Sentinel-1 produites à l'aide de la première approche. Toutes ces méthodes ont montré leurs bonnes performances - **précision, stabilité, robustesse** - dans la littérature. Pour les expériences de classifications menées dans ce chapitre, les quatre paramètres du *RF* utilisés sont les mêmes qu'au Chapitre 4 : 1) $K = 100$, 2)

$m = \sqrt{p}$, 3) $max_depth = 25$, et 4) $min_samples = 5$ en fixant toujours un nombre de 40 000 échantillons d'apprentissage par classe quand c'est possible. Pour les expériences de fusion tardive utilisant les méthodes de fusion par apprentissage, un nombre 500 échantillons par classe quand c'est possible, est utilisé pour l'apprentissage des classifieurs.

5.2.3 Données satellitaires et de référence

Les différentes expérimentations menées dans ce chapitre sont pour deux types de données : 1) les données Sentinel-1 et 2) les données Sentinel-2.

5.2.3.1 Données satellitaires

Dans chacune des deux zones d'intérêt *T33PUL* et *T32NPL*, seules les bandes spectrales à une résolution spatiale de 10 et 20 mètres de Sentinel-2 sont utilisées. Les bandes à 20 mètres sont ré-échantillonnées à 10 mètres en utilisant une méthode d'interpolation spatiale bicubique dans la chaîne de traitement *iota*². Les bandes spectrales à 10 mètres de résolution spatiale d'images radar Sentinel-1 en *GRD* et d'amplitudes réelles acquises uniquement dans le mode *IW* ont été utilisées. Par la suite, ces images radar ont été ortho-rectifiées sur les grilles d'images Sentinel-2.

Dans chaque zone d'intérêt, les images Sentinel-1 en mode *IW* sont utilisées en polarisation *VH+VV* avec une taille du pixel au sol ramenée à $10m \times 10m$ et un nombre de vues correspondant à 4.

5.2.3.2 Données de référence

On reprend les trois légendes du Chapitre 4 : 1) *OSM*, 2) *OSM+INC*, et 3) *OSM+INC+GLC* comportant respectivement cinq, neuf et douze classes.

5.2.4 Plan d'expérimentations

Cette partie présente l'évaluation quantitative des performances du *RF* et l'évaluation qualitative des résultats de classification sur l'étendue de chaque zone d'intérêt (*T33PUL* et *T32NPL*) et propose une étude statistique pour les deux types de comparaison : 1) la **comparaison pixel à pixel**, et 2) la **comparaison par région** en mesurant les distances euclidiennes entre les distributions de classes des classifications mensuelles et de la classification de l'année complète 2018.

Afin d'étudier comparativement pixel à pixel et par région entre les distributions de classes des classifications et fusions de classifications produites, la première stratégie est utilisée : L'auto-entraînement est testé sur l'étendue d'une tuile Sentinel-2 avec les images radar en fonction des légendes utilisées.

5.3 Apport de séries temporelles d'images Sentinel-1

Étant donné qu'on peut entraîner et appliquer un classifieur *RF* sur une même tuile (zone d'intérêt) de la zone d'étude et combiner par la suite les résultats de chaque algorithme du *RF* sans que le résultat final ne soit modifié en utilisant la propriété du vote majoritaire d'un ensemble d'arbres de décision décorrélés de la fonction de décision du *RF*, cette expérience est menée, ici, en utilisant les images radar Sentinel-1 dont l'apport sur le résultat final est quantifié et qualifié.

De manière identique au Chapitre 4, l'ensemble des métriques sont ici, calculées en une seule exécution utilisant les mêmes ensembles d'apprentissage et de validation (d'environ 2 millions de pixels chacun) au cours des travaux. Une évaluation visuelle de la qualité des différentes classifications

produites avec chaque légende est également proposée pour mettre en évidence certains types d'erreurs qui ne peuvent pas être détectées dans l'évaluation statistique globale.

5.3.1 Zone d'intérêt T33PUL (ZONE1, Nord)

Les extraits des différentes classifications supervisées de séries temporelles d'images optiques et radar Sentinel-1_L1/-2_L2A de l'année complète 2018 avec les légendes à 5, 9 et 12 classes, de la zone d'intérêt T33PUL sont présentées dans les Figures 5.4B, 5.5A et 5.5B respectivement.

5.3.1.1 Evaluation quantitative des classifications supervisées de la zone d'intérêt T33PUL

Les Figures 5.6 et 5.7 présentent respectivement les métriques de qualité globale - F-Scores moyens (FS) et coefficients Kappa (K) des classifications supervisées de séries temporelles d'images optiques et radar Sentinel-1_L1/-2_L2A des mois et de l'année complète 2018 pour les trois légendes. Quelle que soit la légende, les valeurs de FS et de K sont variables et très faibles ($0,02 < FS < 0,41$) et ($0,01 < K < 0,36$). **Les résultats les plus forts sont associés aux classifications des mois de février pour la légende à 9 classes et novembre pour la légende à 12 classes et de l'année complète pour la légende à 5 classes si l'on considère les FS et aux classifications du mois de septembre pour la légende à 12 classes et de l'année complète pour les légendes à 5 et 9 classes si l'on considère les K.** Au contraire, les résultats les plus faibles sont associés aux classifications des mois de mai pour la légende à 5 classes et d'août pour les légendes à 9 et 12 classes si l'on considère les FS et les K. Ces résultats sont en accord avec ceux obtenus dans la littérature, qui montrent l'apport de la combinaison d'images optiques et radar pour la cartographie des classes difficiles comme les classes VNC et VHB avec la légende à 12 classes qui apparaissent davantage détectées et mieux discriminées.

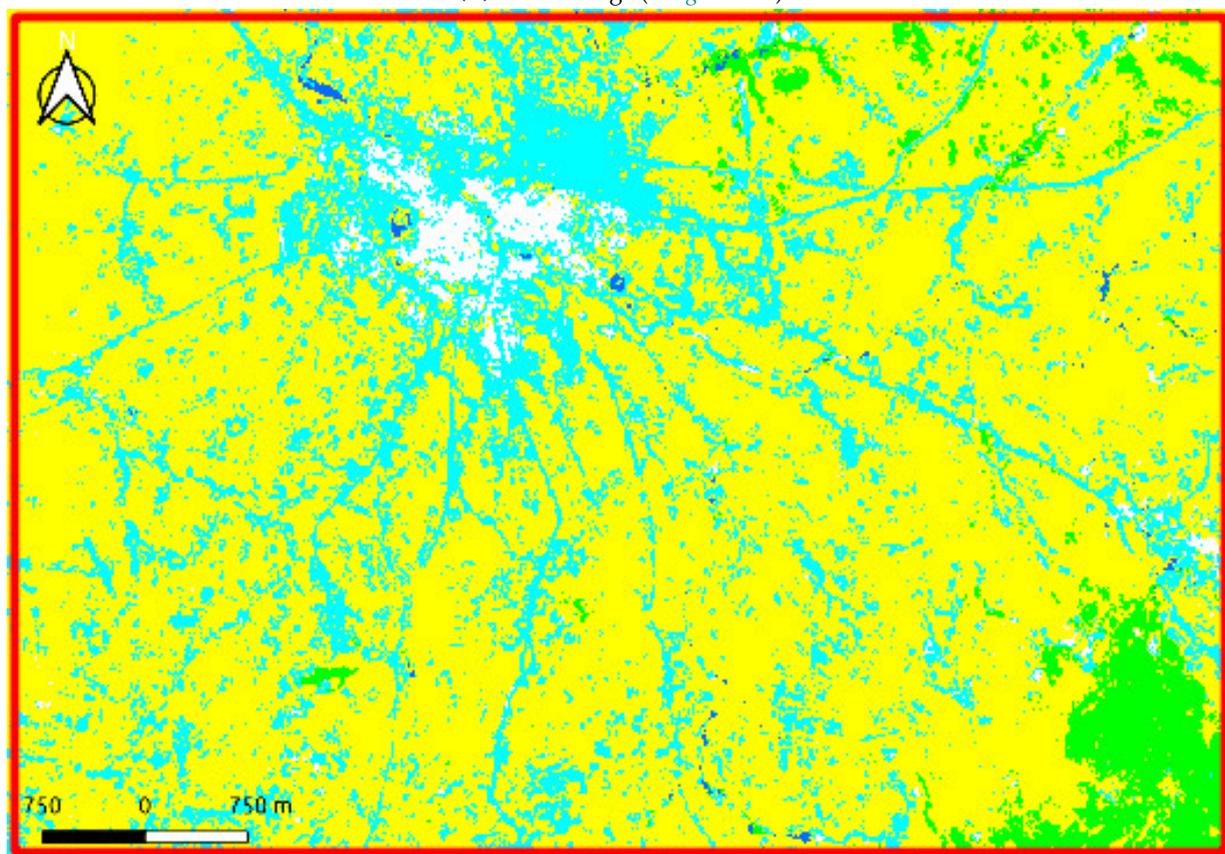
La Figure 5.8 présente les métriques de qualité par classe - F-Score (FS/classe), précision utilisateur (PU) et précision producteur (PP) des classifications supervisées de séries temporelles d'images optiques et radar Sentinel-1_L1/-2_L2A des mois et de l'année complète 2018 pour la légende à 5 classes. L'utilisation de cette légende permet d'améliorer la classification annuelle des classes VGT (FS (VGT) $\simeq 0,53$) et AGR (FS (AGR) $\simeq 0,81$). De plus, les classes RTE (FS (RTE) $\simeq 0,03$); BTM (FS (BTM) $\simeq 0,12$) et EAU (FS (EAU) $\simeq 0,43$) sont respectivement améliorées dans les classifications des mois de décembre, octobre et d'août pour la légende à 5 classes.

Les Tableaux 5.1, 5.2 et 5.3 présentent les matrices de confusion du point de vue producteur. Ils permettent l'analyse détaillée par paire de classes **des erreurs de classification se fondant sur la stratégie STR1 qui utilise ici, la combinaison d'images optiques et radar par rapport à celles avec les images optiques seules au Chapitre 4.** Il existe toujours des confusions entre les classes lorsque l'on utilise les données optiques et radar pour toutes les légendes.

Dans ces tableaux, les pixels identifiés en classe VGT se trouvent moins classifiés en AGR et le taux de FP, avec la classe AGR, baisse ici de 38,9% à 24,6% avec l'utilisation de la combinaison de séries d'images optiques Sentinel-2 et radar Sentinel-1 pour la légende à 5 classes. La confusion s'accroît plutôt avec l'utilisation des classes FRT; PRA et ARB, et les taux de FP augmentent de 14,5% à 17,5% pour la classe FRT puis de 13% à 15,8% pour la classe PRA et de 17,3% à 20% pour la classe ARB. Concernant la confusion avec la classe EAU, elle s'accroît et le taux de FP augmente pour la légende à 5 classes de même que pour les classes SFE et surtout RIV (de 5,1% à 35,8%) de la légende à 9 classes. De plus, cette confusion s'accroît toujours avec l'ajout de nouvelles classes pour la légende à 12 classes. C'est ainsi que **la confusion entre les classes VNC et RIV s'accroît fortement avec un taux de FP qui**

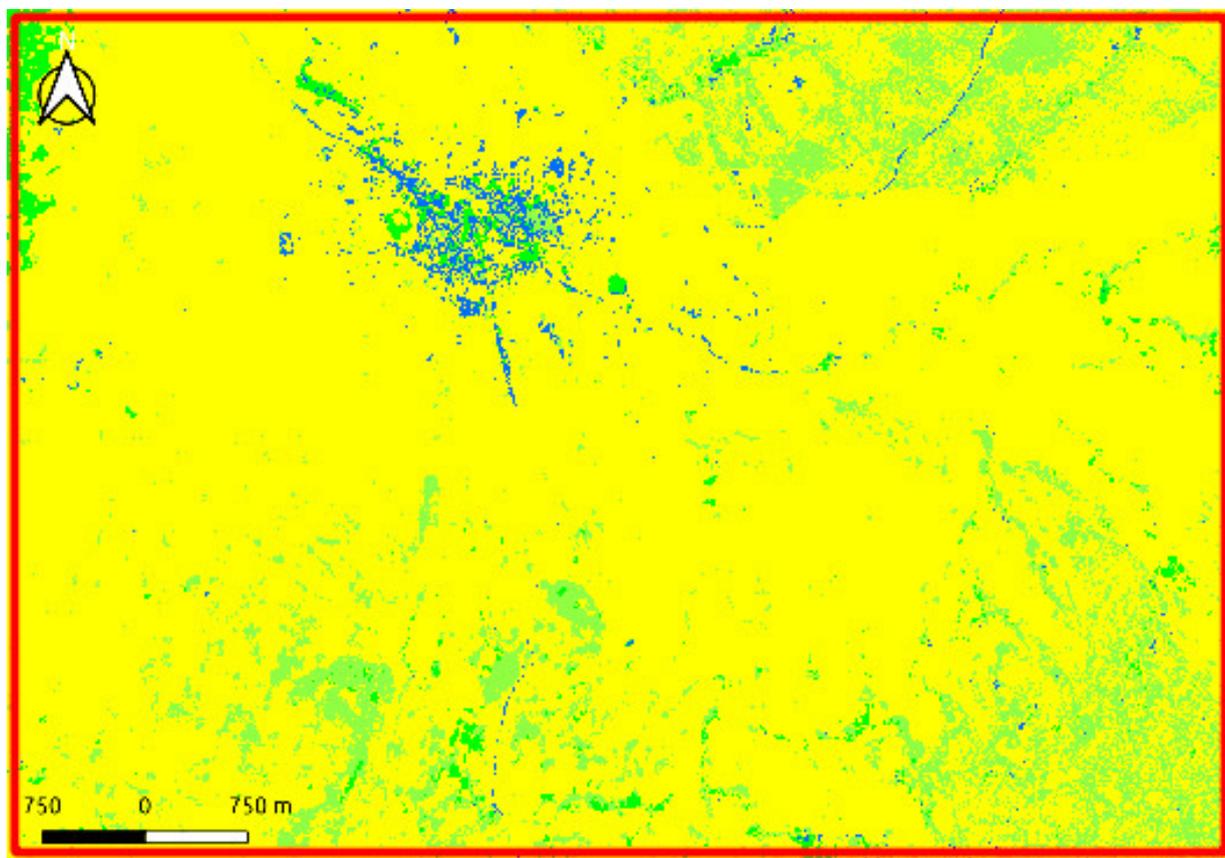


(A) Ortho-image (Google Earth)

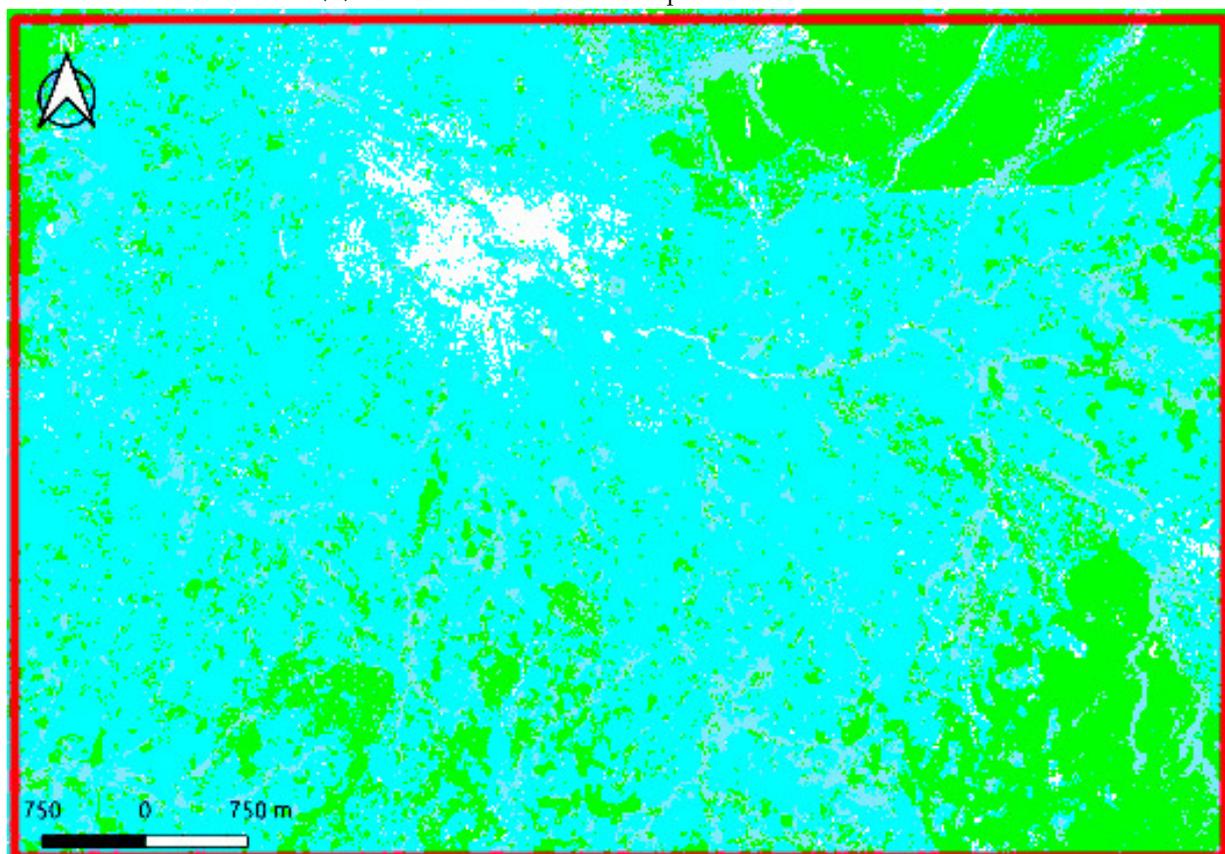


(B) Classification de l'année complète 2018 avec 5 classes

FIG. 5.4 – Extraits de l'ortho-image et de la classification supervisée de séries temporelles d'images optiques et radar Sentinel-1_L1/-2_L2A avec la légende à 5 classes : ■ : VGT ; ■ : AGR ; ■ : EAU ; ■ : RTE ; ■ : BTM, de la zone d'intérêt T33PUL.



(A) Classification de l'année complète 2018 avec 9 classes



(B) Classification de l'année complète 2018 avec 12 classes

FIG. 5.5 – Extraits des classifications supervisées de séries d'images Sentinel-1_L1/-2_L2A avec les légendes à 9 : ■ : FRT; ■ : PRA; ■ : ARB; ■ : AGR; ■ : SFE; ■ : ZHU; ■ : RIV; ■ : RTE; ■ : BTM et 12 : ■ : VNC; ■ : VHB; ■ : FOU; ■ : FFE; ■ : TCU; ■ : ARB; ■ : ZHH; ■ : SFE; ■ : ZHU; ■ : RIV; ■ : RTE; ■ : BTM classes, de la zone T33PUL.

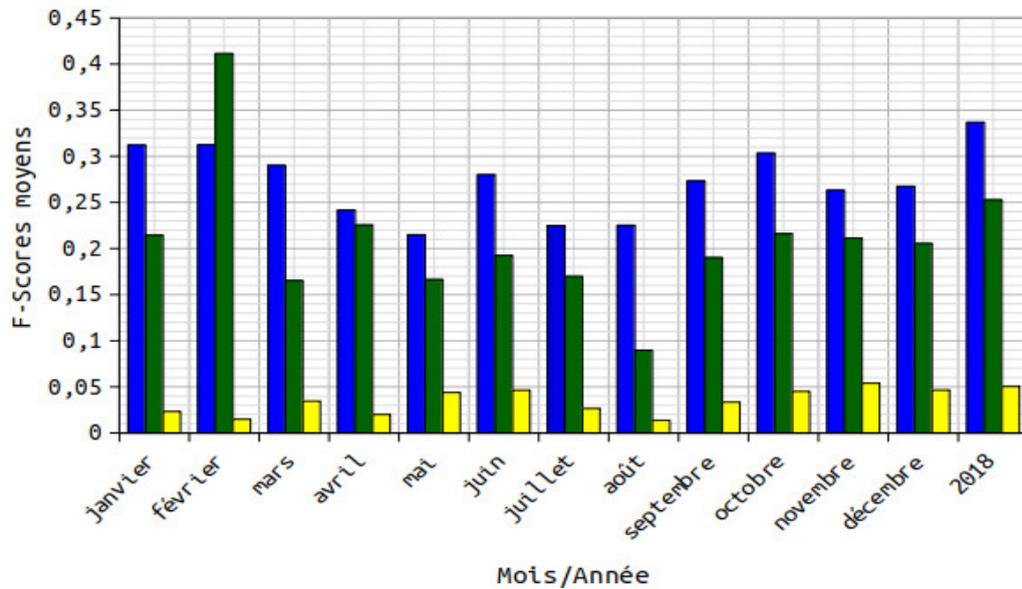


FIG. 5.6 – F-Scores moyens des classifications supervisées de séries temporelles d’images optiques et radar Sentinel-1_L1/-2_L2A avec les légendes à 5 : ■ : OSM et 9 : ■ : OSM+INC et 12 : ■ : OSM+INC+GLC classes, de la zone d’intérêt T33PUL.

augmente de 38,3% à 57,6%. Cette augmentation de FP se fait au détriment des FN, avec une forte diminution de ceux-ci lors de l’utilisation de la combinaison d’images optiques et radar.

Par ailleurs, avec la combinaison d’images optiques et radar Sentinel-1_L1/-2_L2A pour la légende à 5 classes sur la zone d’intérêt T33PUL, la classe RTE est classifiée en AGR avec un taux de $FP=21,5\%$. À l’inverse, la classe AGR est classifiée en RTE avec un taux inférieur de $FN=16,2\%$. Ce taux baisse drastiquement à $FN=0,9\%$ de même que le taux de FP qui devient $FP=0,2\%$ et la confusion s’atténue donc fortement pour la légende à 9 classes. De plus, pour cette légende, les classes SFE et RIV sont classifiées en RTE et ARB avec des taux de $FP=0,1\%$ et $FP=4,5\%$ respectivement. Inversement, les classes RTE et ARB sont classifiées en SFE et RIV avec des taux supérieur de $FN=0,6\%$ et inférieur de $FN=0,3\%$ respectivement. Ces taux baissent ou augmentent et deviennent $FN=0\%$ et $FN=12,3\%$. Par contre, les taux de FP baissent à $FP=0,2\%$ et $FP=0\%$ et les confusions s’atténuent également fortement pour la légende à 12 classes. En outre, pour la légende à 9 classes, la classe RTE est classifiée en RIV avec un faible taux de $FP=0,2\%$. À l’inverse, la classe RIV est classifiée en RTE avec un taux encore plus faible de $FN=0,1\%$. Ce taux augmente grandement à $FN=20,2\%$ contrairement au taux de FP qui baisse drastiquement et devient $FP=2,3\%$ et la confusion s’atténue dans ce cas pour la légende à 12 classes. En général, **les taux de FN augmentent grandement et la discrimination des classes d’OCS est ici meilleure en utilisant la combinaison d’images optiques et radar Sentinel-1_L1/-2_L2A pour les légendes à 9 et 12 classes.**

Les confusions qui impliquent la classe EAU (RIV et ARB) s’expliquent par la séparabilité de cette dernière qui serait liée à la diffusion inhérente à sa constitution. En effet, dans les hyperfréquences, en saison de pluies, la classe ARB contribuerait moins à la rétrodiffusion du signal, et il y aurait plus d’impact de la structure de l’eau. Les synthèses de séries temporelles d’images optiques Sentinel-2_L3A pourraient permettre de prendre en compte la structure de la classe ARB, et de s’affranchir des confusions entre cette dernière et la classe RIV. **La complémentarité entre les synthèses de séries**

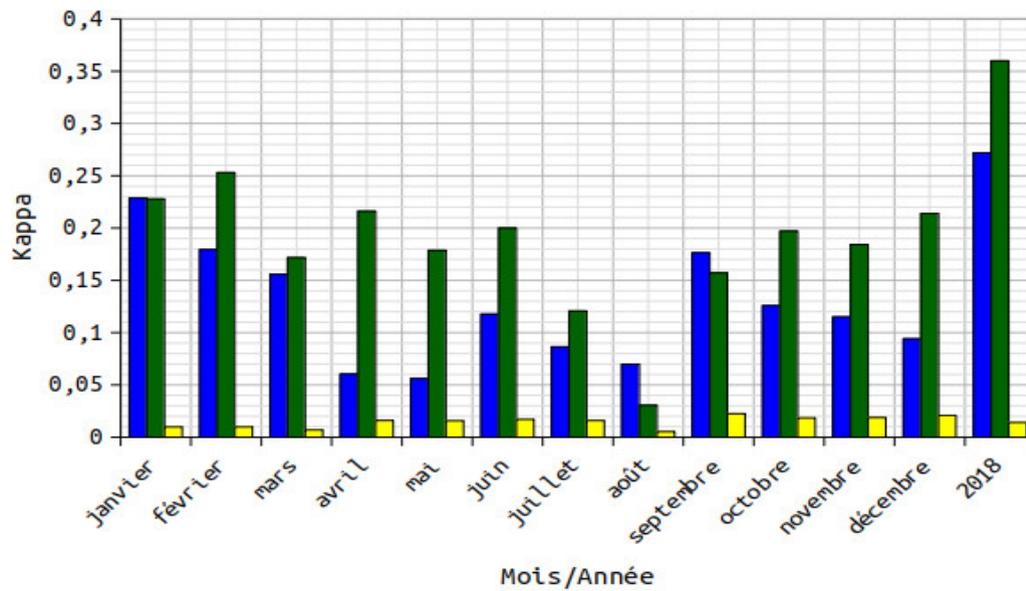


FIG. 5.7 – Coefficients Kappa des mêmes classifications que les FS dans la Figure 5.6.

d'images optiques et les séries d'images radar devraient permettre de réduire les confusions entre les classes EAU (RIV) et VGT (ARB).

TAB. 5.1 – Matrice de confusion avec la légende à 5 classes.

L1-L2A		Vérité Terrain					PU
% VU	CL	VGT	AGR	EAU	RTE	BTM	
11,8	VGT	64,1	9,9	5,6	2,8	0,3	46,1
77,1	AGR	24,6	71,0	37,3	21,5	3,4	95,0
2,2	EAU	8,1	2,3	49,4	0,4	0,1	12,4
0,1	RTE	2,8	16,2	6,2	64,0	9,4	1,4
0,1	BTM	0,3	0,8	1,5	11,3	86,9	5,8
	PP	64,1	71,0	49,4	64,0	86,9	

TAB. 5.2 – Matrice de confusion avec la légende à 9 classes.

L1-L2A		Vérité Terrain									PU
% VU	CL	FRT	PRA	ARB	AGR	SFE	ZHU	RIV	RTE	BTM	
0,8	FRT	54,1	45,9	20,5	3,2	0,5	11,2	4,4	3,7	7,4	2,2
7,4	PRA	20,0	33,4	3,7	4,6	0,0	0,9	1,2	1,1	0,2	33,4
4,1	ARB	7,6	11,2	55,7	4,1	0,3	8,2	4,5	2,8	2,2	16,0
77,1	AGR	17,5	15,8	20,0	87,6	0,9	0,6	35,8	0,2	0,8	94,5
4,2	SFE	0,8	0,3	0,1	0,4	98,3	17,8	0,7	0,6	7,6	74,3
0,9	ZHU	0,3	0,5	0,6	0,7	0,2	61,8	0,7	0,1	0,2	0,1
0,2	RIV	0,4	0,6	0,3	0,7	0,4	0,3	54,1	0,2	0,7	0,1
0,1	RTE	0,6	0,4	0,7	0,9	0,1	0,2	0,1	91,8	0,7	0,1
0,1	BTM	0,2	0,3	0,2	0,7	0,0	0,2	0,7	0,1	82,6	0,1
	PP	54,1	33,4	55,7	87,6	98,3	61,8	54,1	91,8	82,6	

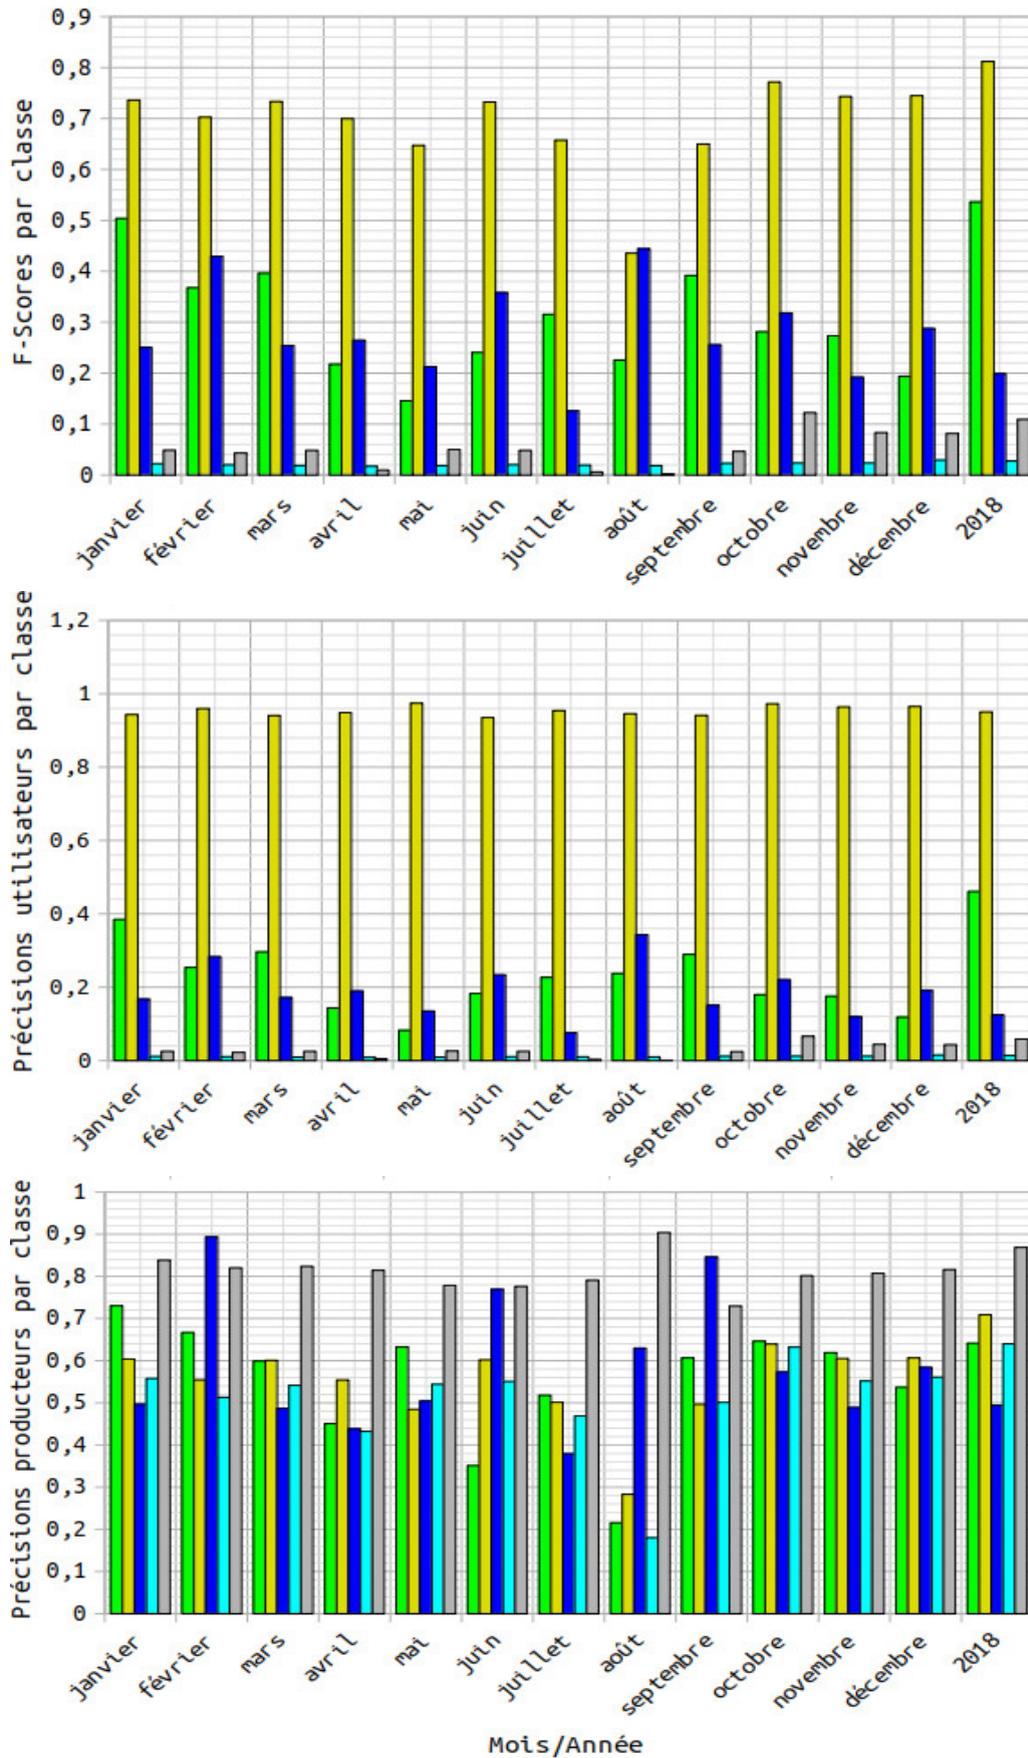


FIG. 5.8 – F-Scores et précision utilisateur et précision producteur par classe des classifications supervisées de séries d'images Sentinel-1_L1/-2_L2A avec la légende à 5 classes : ■ : VGT; ■ : AGR; ■ : EAU; ■ : RTE; ■ : BTM, de la zone d'intérêt T33PUL.

TAB. 5.3 – Matrice de confusion avec la légende à 12 classes.

L1-L2A		Vérité Terrain												PU
% VU	CL	VNC	VHB	FOU	FFE	TCU	ARB	ZHH	SFE	ZHU	RIV	RTE	BTM	
0,1	VNC	37,2	0,4	0,0	0,0	0,0	0,0	0,6	0,5	0,7	0,1	0,0	0,0	8,9
0,6	VHB	4,8	75,0	0,2	0,4	0,2	0,5	0,8	0,7	0,6	28,0	7,6	1,1	5,3
4,5	FOU	0,0	0,0	71,9	0,0	0,0	0,0	0,0	0,0	0,0	0,0	0,0	0,0	0,1
0,5	FFE	0,0	0,0	0,0	59,0	0,0	0,0	0,0	0,0	0,0	0,0	0,0	0,0	0,1
45,0	TCU	0,0	0,0	0,0	0,0	50,6	0,0	0,0	0,0	0,0	0,0	0,0	1,0	0,1
18,2	ARB	0,0	0,0	0,0	0,0	0,0	60,9	0,0	0,0	0,0	0,0	0,0	0,0	0,1
11,5	ZHH	0,0	0,0	0,0	0,0	0,0	0,0	54,1	0,0	0,0	0,0	0,0	0,0	0,1
4,2	SFE	0,0	0,0	0,0	0,0	0,0	0,0	0,0	92,6	0,0	0,0	0,0	0,0	0,1
0,9	ZHU	0,0	0,0	0,0	0,0	0,0	0,0	0,0	0,0	71,0	0,0	0,0	0,0	0,1
0,2	RIV	57,6	10,2	21,3	40,0	7,3	12,3	43,6	0,6	18,2	50,2	2,3	0,2	0,8
0,1	RTE	0,3	12,8	6,7	1,0	41,1	26,3	1,5	0,2	9,5	20,2	80,0	12,1	2,9
0,1	BTM	0,1	1,6	0,1	0,0	1,0	0,5	0,2	0,0	0,5	1,6	10,2	86,6	17,3
	PP	37,2	75,0	71,9	59,0	50,6	60,9	54,1	92,6	71,0	50,2	80,0	86,6	

% VU : pourcentage de données vecteurs utilisées.

CL : classification.

5.3.1.2 Utilisation des confiances des classifications supervisées de la zone d'intérêt T33PUL

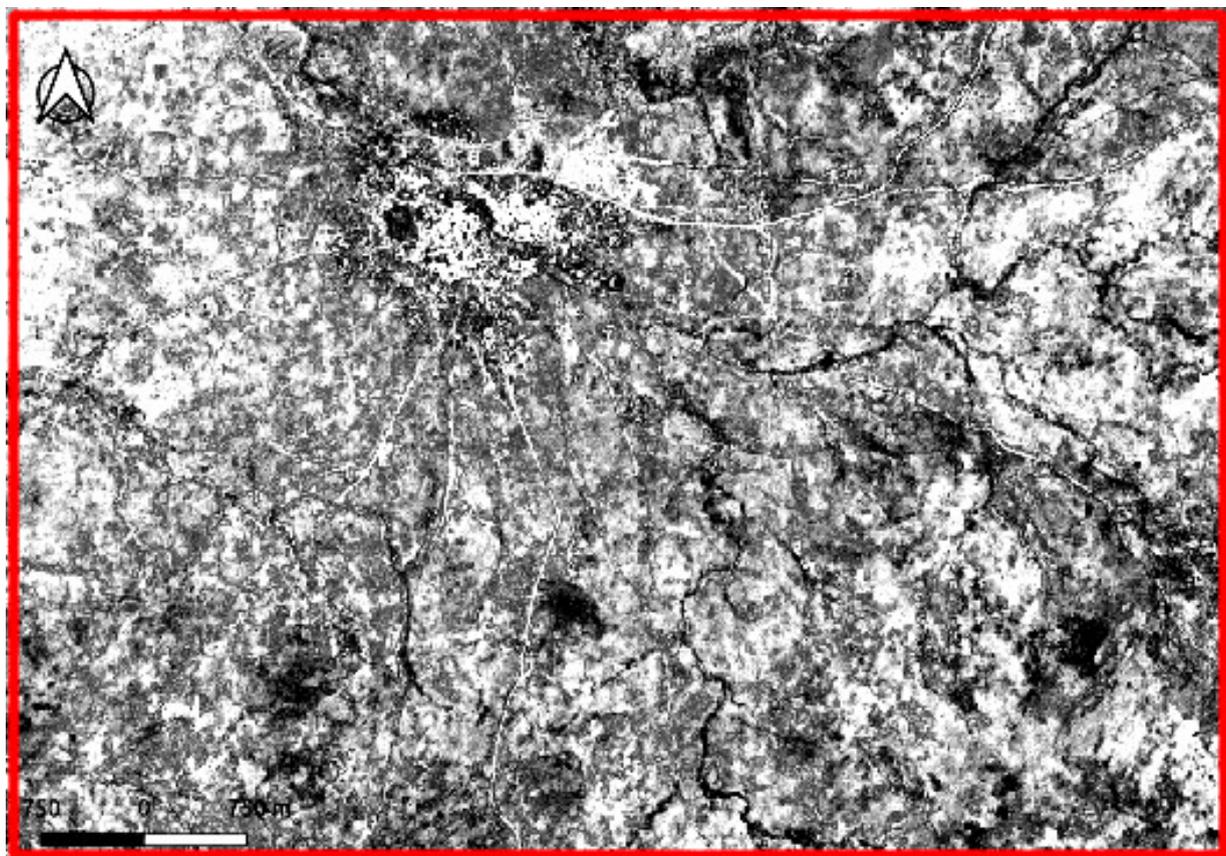
Les Figures 5.9A, 5.9B et 5.10 montrent les extraits de cartes de confiance obtenues sur la zone d'intérêt T33PUL, en résonance aux Figures 5.4B, 5.5A et 5.5B pour les légendes à 5, 9 et 12 classes respectivement. De nouveau, on peut observer que les valeurs de confiance augmentent globalement avec le nombre de classes et localement lorsque le nombre de classes augmente. **De plus, l'utilisation de la combinaison d'images optiques et radar a permis d'outrepasser la présence de résidus de nuages et leurs ombres sur cette zone d'intérêt et de renforcer la confiance de classification des classes d'OCS de la légende à 12 classes** qui sont désormais reconnaissables dans la partie sud-est de la Figure 5.10. Dans cette dernière partie, les classes d'OCS de la légende à 9 classes sont par contre difficiles à reconnaître malgré la présence d'images radar Sentinel-1.

5.3.1.3 Évaluation qualitative sur la zone T33PUL

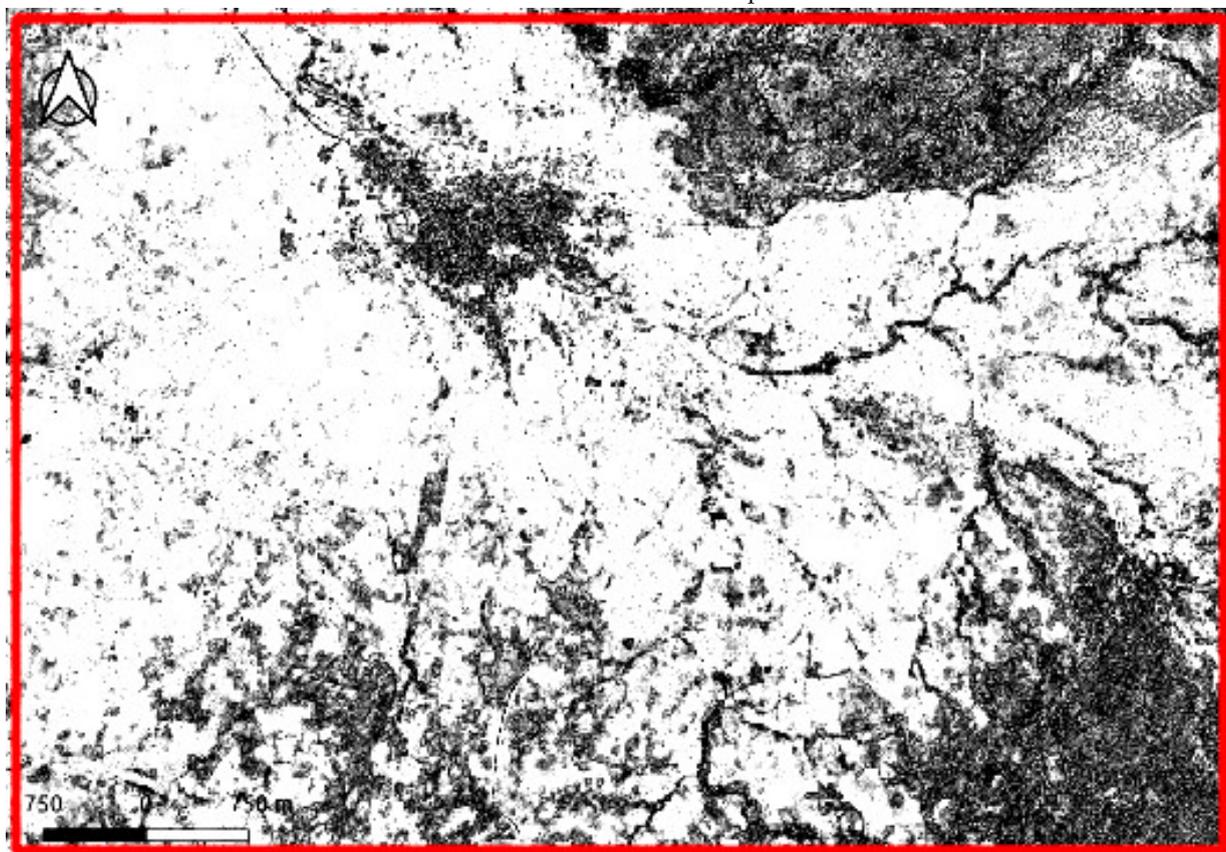
Les métriques quantitatives sur une très grande surface ne sont toujours pas en mesure de révéler plusieurs types d'erreurs présentes dans les cartes d'OCS malgré l'utilisation ici de la combinaison d'images optiques et radar. C'est ainsi qu'une inspection visuelle est nécessaire afin d'identifier différents problèmes qui sont également analysés dans cette section.

5.3.1.3.1 Paysages difficiles dans les classifications supervisées de la zone d'intérêt T33PUL Afin de mettre en évidence l'avantage des méthodes de classification supervisée et de fusion sur des zones fragmentées ou les régions à topographie irrégulière, une étude qualitative comparative visuelle des classifications ainsi que les fusions de ces classifications est nécessaire. Cette étude vise à déterminer si les images radar influencent la confiance des méthodes de classification supervisée et de fusion. Ainsi, les résultats de classification et de fusion sont étudiés en détail dans cette section sur deux types de zones : **une zone rurale (Figure 5.11) et une zone urbaine (Figure 5.12).**

La zone rurale de la Figure 5.11A est la même que celle de la Figure 4.13A. Les différentes classifications et confiances sont présentées sur les Figures 5.11B-F. Les différentes classes ne ressortent pas bien pour la légende à 9 classes (Figure 5.11C), contrairement aux classes d'OCS qui sont assez bien représentées pour les légendes à 5 et 12 classes sur les Figures 5.11B et 5.11D : **la classification ne permet pas d'isoler de manière individuelle les classes de la légende à 9 classes, mais elle**



(A) Confiance de la classification de l'année complète 2018 avec 5 classes



(B) Confiance de la classification de l'année complète 2018 avec 9 classes

FIG. 5.9 – Extraits des confiances de classification supervisée de séries temporelles d'images optiques et radar Sentinel-1_L1/-2_L2A : ■ : faibles → □ : fortes valeurs, de la zone d'intérêt T33PUL.

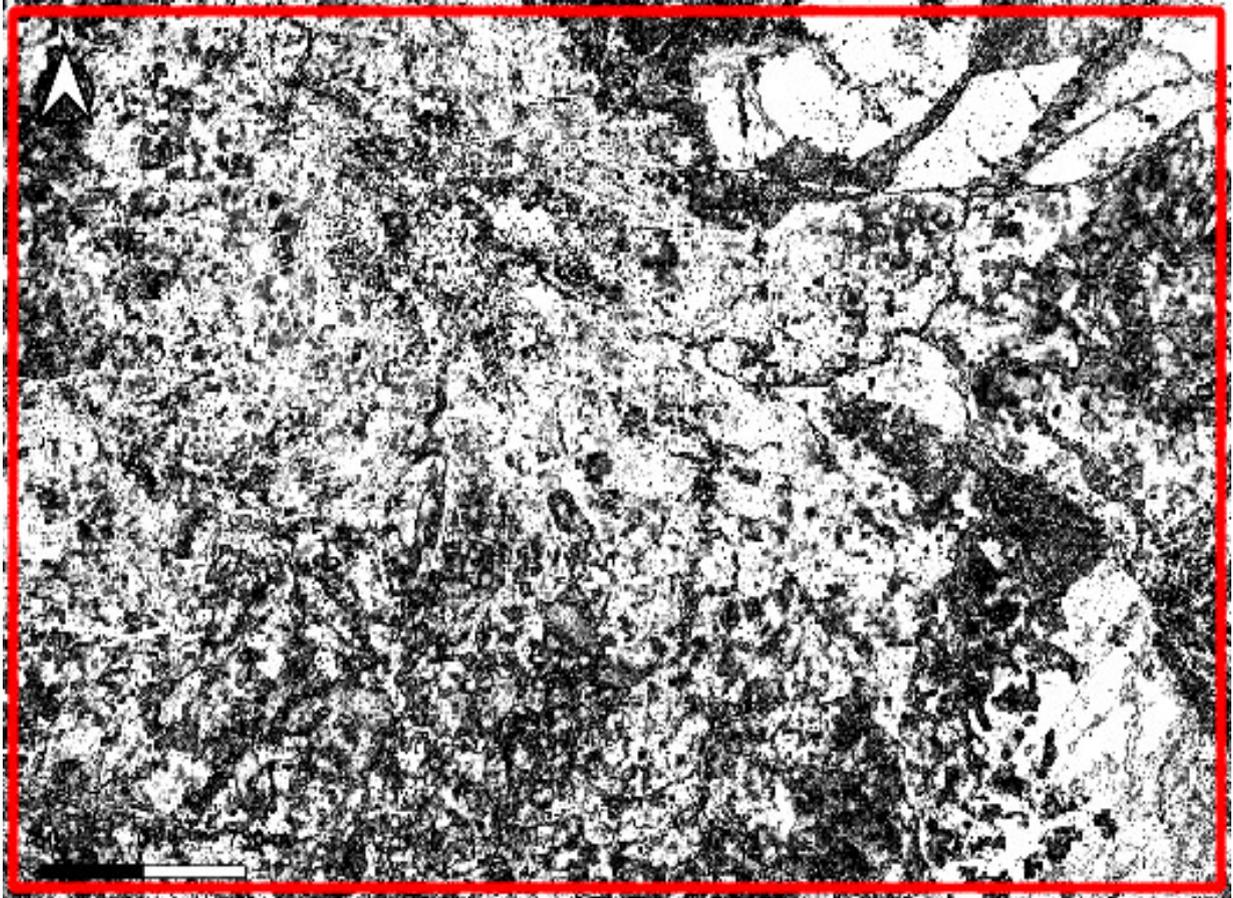


FIG. 5.10 – Extrait de la confiance de la classification supervisée de séries d’images Sentinel-1_L1/-2_L2A avec la légende à 12 classes, de la zone d’intérêt T33PUL.

permet d’identifier celles des légendes à 5 et 12 classes. On peut remarquer plusieurs confusions entre les classes pour la légende à 9 classes sur la Figure 5.11C. Pour cette dernière légende, la plupart des classes sont non ou mal représentées. En effet, toutes les classes ne sont pas détectées ou alors s’entremêlent et se confondent lorsqu’elles le sont. Cependant, certaines classes parviennent à être détecter en posant quelques problèmes négligeables. Par exemple, les classes RTE et BTM sont mieux représentées pour la légende à 5 classes (Figure 5.11B). Bien que la classe EAU contient quelques zones d’ombres, elle est assez bien ressortie pour la légende à 5 classes.

La zone urbaine de la Figure 5.12B est la même que celle décrite dans la Figure 4.14B. Pour la légende à 5 classes, la classification des classes RTE et BTM (Figure 5.12A) donne de bons résultats en présentant quelques confusions entre ces classes du fait de la présence d’échantillons mal étiqueté. Cependant les classes SFE ; ZHU et RIV (Figure 5.12C(D)) de la légende à 12 classes (contenues dans la classe EAU de la légende à 5 classes) sont plutôt très peu détectées, sauf certaines petites rivières (RIV) qui se discriminent assez bien de la classe ZHU pour la légende à 12 classes. **Ces faibles pourcentages de détection pourraient être facilement améliorés en utilisant par exemple les synthèses mensuelles de séries temporelles de la combinaison d’images Sentinel-1_L1/-2_L3A.**

5.3.1.3.2 Petites classes locales dans les classifications supervisées de la zone d’intérêt T33PUL

Les classes minoritaires sont difficiles à cartographier en raison de leur manque de représentativité lors de l’entraînement des classifieurs. Des exemples typiques sont les classes VNC ; RTE ; BTM ; RIV ;

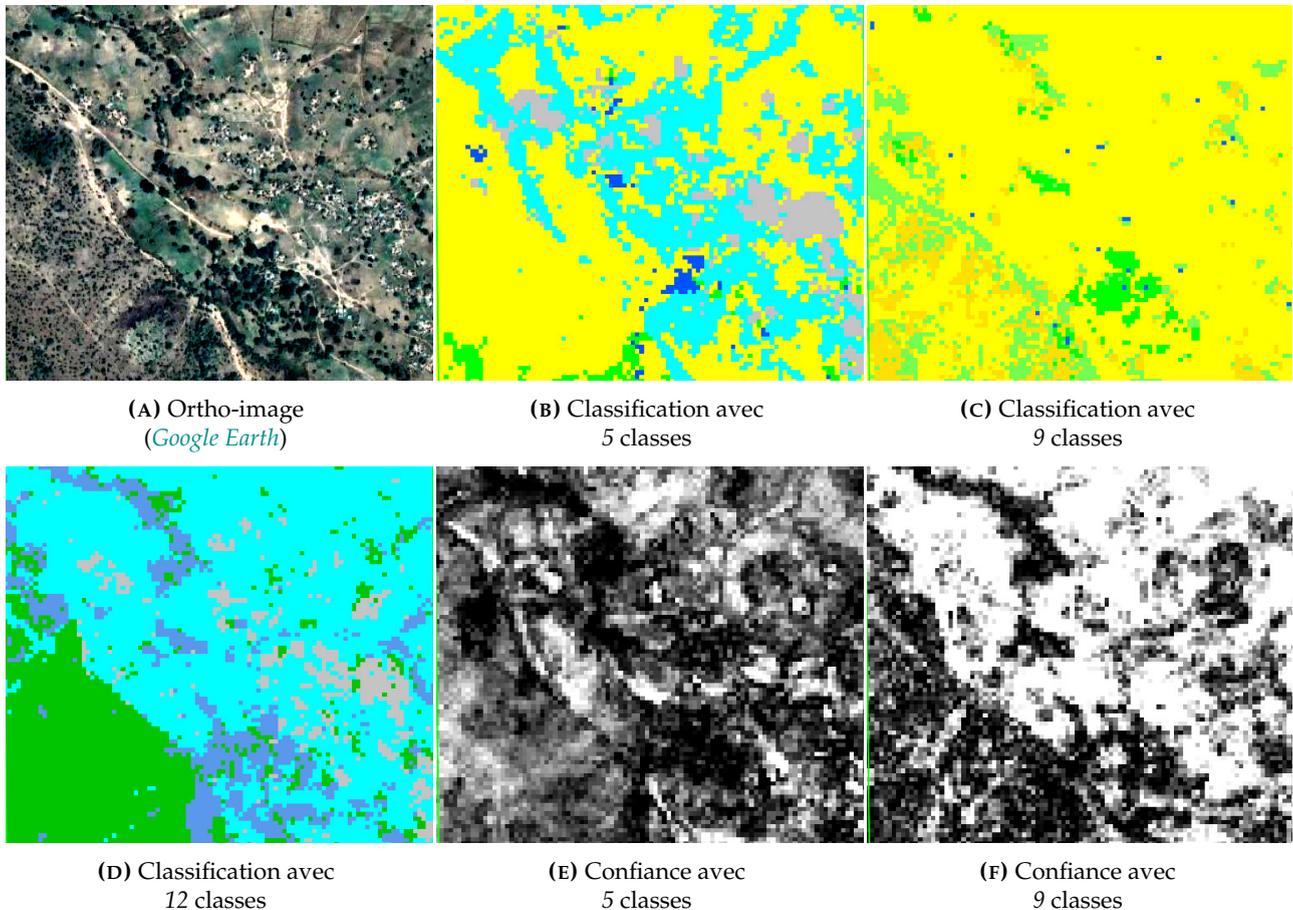


FIG. 5.11 – Extraits de l’ortho-image et des classifications et des confiances de classifications de séries temporelles d’images optiques et radar Sentinel-1_L1/-2_L2A avec les légendes à 5 et 9 et 12 classes, d’une zone rurale sur la zone d’intérêt T33PUL.

VHB et ZHU. Ces classes sont concentrées dans des régions spécifiques de la zone d’intérêt T33PUL. Les Figures 5.13B et 5.13C illustrent comment les légendes à 9 et 12 classes confondent toutes les classes alors que la légende à 5 classes réduit les confusions entre les classes sur la Figure 5.13D.

5.3.1.4 Comparaison pixel à pixel des classifications supervisées de la zone d’intérêt T33PUL

L’objectif de cette section est d’effectuer la comparaison pixel à pixel entre les classifications des différents mois et de l’année complète 2018, de séries temporelles d’images optiques et radar Sentinel-1_L1/-2_L2A, de la zone d’intérêt T33PUL. Le Tableau 5.4 présente les différentes valeurs du coefficient Kappa (K) et du F-Score moyen (FS) obtenues au terme de la comparaison pixel à pixel des classifications supervisées des douze mois et de l’année complète 2018 de séries temporelles d’images optiques et radar Sentinel-1_L1/-2_L2A utilisant la légende à 9 classes et de la VT, de la zone d’intérêt T33PUL.

Dans ce tableau, on peut globalement voir que les scores de similarité K et FS issus de la comparaison entre les classifications de la plupart des mois et de l’année complète et la VT, sont relevés et traduisent ici le fait que ces classifications se rapprochent l’une de l’autre. Les résultats de deux classifications sont davantage proches. Ce qui implique un **taux d’accord élevé entre les différentes classifications**. Plus précisément, les valeurs de K et de FS sont moins élevées seulement dans les classifications des mois de mai à septembre et décembre par rapport à la VT qui possèdent ainsi les plus faibles

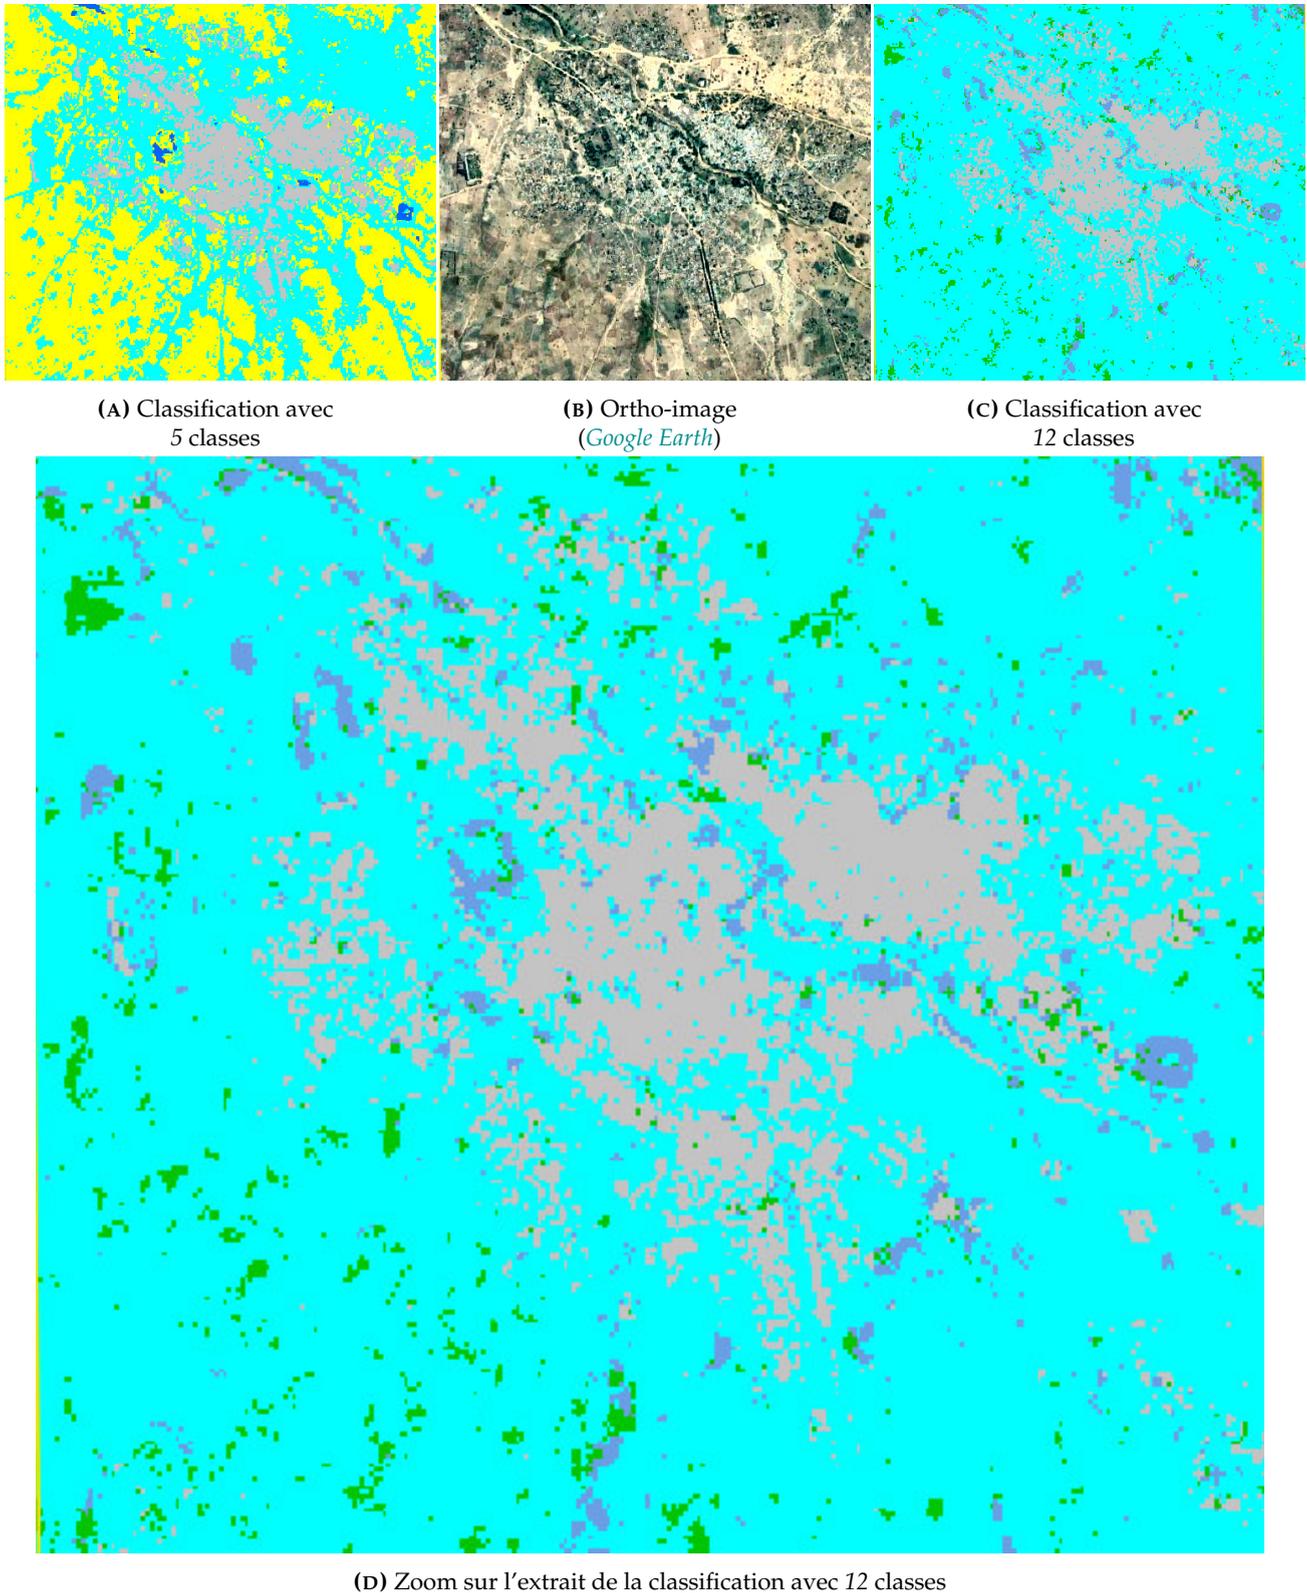


FIG. 5.12 – Extraits de l'ortho-image et des classifications de séries temporelles d'images optiques et radar Sentinel-1_L1/-2_L2A avec les légendes à 5 : ■ : VGT; ■ : AGR; ■ : EAU; ■ : RTE; ■ : BTM et 12 : ■ : VNC; ■ : VHB; ■ : FOU; ■ : FFE; ■ : TCU; ■ : ARB; ■ : ZHH; ■ : SFE; ■ : ZHU; ■ : RIV; ■ : RTE; ■ : BTM classes, d'une zone urbaine sur la zone d'intérêt T33PUL.

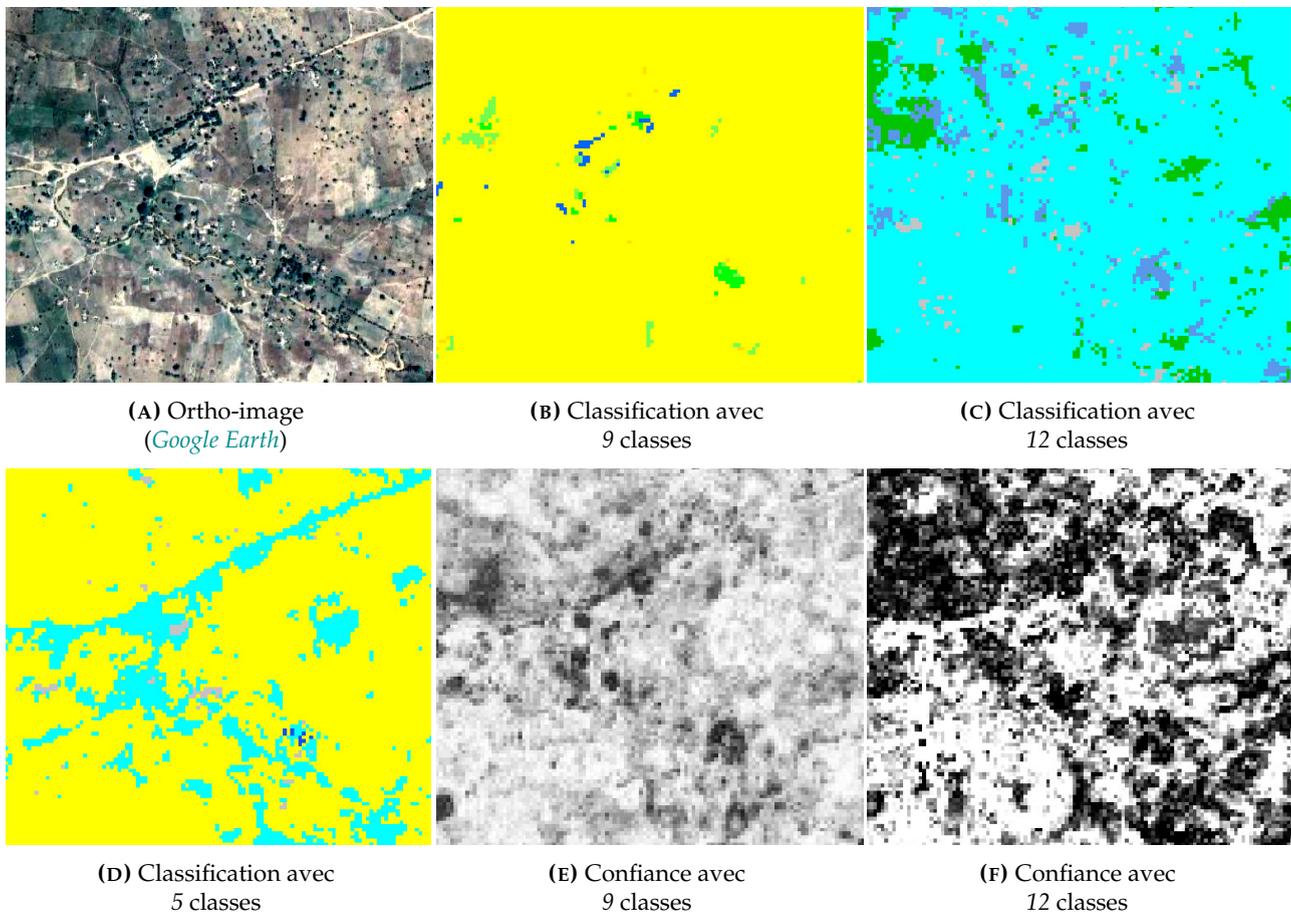


FIG. 5.13 – Extraits de l’ortho-image et des classifications et des confiances de classifications de séries temporelles d’images optiques et radar Sentinel-1_L1/-2_L2A avec les légendes à 5 et 9 et 12 classes, de petites classes locales sur la zone d’intérêt T33PUL.

taux d’accord. Au contraire, les classifications des mois de janvier à avril, octobre, novembre et de l’année complète 2018 possèdent les plus forts taux d’accord par rapport aux autres classifications.

5.3.1.5 Comparaison par région des distributions de classes des classifications supervisées de la zone d’intérêt T33PUL

L’objectif de cette section est de comparer en effectuant la moyenne des scores calculées au sein de grandes régions extraites des classifications des différents mois et de l’année complète 2018, de séries temporelles d’images optiques et radar Sentinel-1_L1/-2_L2A, de la zone d’intérêt T33PUL. Le Tableau 5.5 présente les moyennes des scores calculés au sein de cellules de taille 200 pixels extraites des classifications supervisées des douze mois et de l’année complète 2018 de séries temporelles d’images optiques et radar Sentinel-1_L1/-2_L2A et de la VT utilisant la légende à 9 classes, de la zone d’intérêt T33PUL.

Dans ce tableau, on peut globalement constater de valeurs relativement faibles des scores de comparaison par région des classifications mensuelles et annuelle et la VT. **La classification du mois d’août demeure très différente des autres classifications avec des scores les plus élevées de 0,58 à 0,85 en raison certainement de la mauvaise qualité de la série d’images optiques de ce mois qui n’a pu être amélioré en combinant avec les images radar.** Par contre, les deux groupes de classifications mensuelles et annuelle (janvier, mars, novembre et 2018) et (janvier, février, juin et

TAB. 5.4 – Coefficients Kappa (K) et F-Scores moyens (FS) obtenus au terme de la comparaison pixel à pixel des classifications mensuelles et annuelle de séries temporelles d’images optiques et radar Sentinel-1_L1/-2_L2A et de la VT avec la légende à 9 classes, de la zone d’intérêt T33PULL.

	jan.	fév.	mar.	avr.	mai	juin	juil.	août.	sep.	oct.	nov.	déc.	2018	VT
<i>k</i> = 9														
L1-L2A	K FS													
janvier	1,0 100,0	0,5 56,2	0,4 52,3	0,4 47,0	0,3 44,5	0,3 44,2	0,3 41,9	0,2 33,5	0,3 44,2	0,5 53,8	0,5 57,0	0,4 51,0	0,4 51,2	0,5 56,2
février	0,5 56,2	1,0 100,0	0,4 49,5	0,4 50,1	0,3 42,9	0,4 46,8	0,3 41,3	0,2 34,0	0,3 42,1	0,4 53,0	0,4 52,1	0,4 50,4	0,4 52,5	0,4 52,3
mars	0,4 52,3	0,4 49,5	1,0 100,0	0,4 48,3	0,3 38,7	0,3 42,6	0,3 40,4	0,1 32,0	0,2 41,7	0,4 48,6	0,4 50,1	0,3 46,7	0,4 51,6	0,4 29,7
avril	0,4 47,0	0,4 50,1	0,4 48,3	1,0 100,0	0,3 37,7	0,3 43,6	0,2 41,4	0,1 32,4	0,2 39,8	0,4 51,1	0,4 48,7	0,3 46,0	0,4 51,0	0,4 28,3
mai	0,3 44,5	0,3 42,9	0,3 38,7	0,3 37,7	1,0 100,0	0,3 44,1	0,2 36,6	0,1 26,9	0,2 38,0	0,3 42,1	0,3 43,9	0,3 38,9	0,3 46,5	0,3 21,9
juin	0,3 44,2	0,4 46,8	0,3 42,6	0,3 43,6	0,3 44,1	1,0 100,0	0,2 37,6	0,1 29,9	0,2 42,0	0,3 43,9	0,3 46,4	0,3 41,5	0,4 52,3	0,3 24,5
juillet	0,3 41,9	0,3 41,3	0,3 40,4	0,2 41,4	0,2 36,6	0,2 37,6	1,0 100,0	0,2 36,2	0,2 37,3	0,3 46,8	0,3 43,2	0,3 42,0	0,2 39,7	0,2 22,2
août	0,2 33,5	0,2 34,0	0,1 32,0	0,1 32,4	0,1 26,9	0,1 29,9	0,2 36,2	1,0 100,0	0,1 32,1	0,2 36,24	0,2 34,4	0,1 33,3	0,1 31,3	0,1 16,4
septembre	0,3 44,2	0,3 42,1	0,2 41,7	0,2 39,8	0,2 38,0	0,2 42,0	0,2 37,3	0,1 32,1	1,0 100,0	0,3 45,5	0,3 46,1	0,3 41,9	0,3 44,1	0,3 23,4
octobre	0,5 53,8	0,4 53,0	0,4 48,6	0,4 51,1	0,3 42,1	0,3 43,9	0,3 46,8	0,2 36,2	0,3 45,5	1,0 100,0	0,5 61,2	0,4 53,3	0,4 53,5	0,4 29,4
novembre	0,5 57,0	0,4 52,1	0,4 50,1	0,4 48,7	0,3 43,9	0,3 46,4	0,3 43,2	0,2 34,4	0,3 46,1	0,5 61,2	1,0 100,0	0,4 52,5	0,4 54,1	0,4 29,5
décembre	0,4 51,0	0,4 50,4	0,3 44,7	0,3 46,0	0,3 38,9	0,3 41,5	0,3 42,0	0,1 33,3	0,3 41,9	0,4 53,3	0,3 52,5	1,0 100,0	0,3 46,8	0,3 24,5
2018	0,4 51,2	0,4 52,5	0,4 51,6	0,4 51,0	0,3 46,5	0,4 52,3	0,2 39,7	0,1 31,3	0,3 44,1	0,4 53,5	0,4 54,1	0,3 46,8	1,0 100,0	0,5 31,1
VT	0,4 29,0	0,3 26,4	0,4 29,7	0,4 28,3	0,3 21,9	0,3 24,5	0,2 22,2	0,1 16,4	0,3 23,4	0,4 29,4	0,4 29,5	0,3 24,5	0,5 31,1	1,0 100,0

k : nombre de classes. VT : vérité terrain.

octobre) se rapprochent des deux classifications des mois d'avril et septembre avec de faibles scores de 0,27 et 0,35 respectivement. De plus, les cinq groupes de classifications mensuelles et annuelle (avril, novembre et décembre); (janvier, février et novembre); (mai, juin et septembre); (avril, mai et juin) et (juin, juillet et 2018) se rapprochent des cinq classifications des mois de février; mai; juillet; août et octobre avec de faibles scores de 0,25; 0,34; 0,43; 0,67 et 0,34 respectivement.

5.3.1.6 Influence de la nomenclature et de la dimension temporelle des données sur T33PUL

La nomenclature (légende) des données de référence et la dimension temporelle des données satellitaires (mensuelles ou annuelle) peuvent modifier les performances de classification. Ainsi, l'impact des périodes sur les résultats de classification précédemment étudiés pour les trois légendes (Section 5.3.1.1) est analysé dans cette section.

5.3.1.6.1 Influence de la nomenclature des données de référence sur les classifications supervisées de la zone d'intérêt T33PUL La nomenclature (légende) des données de référence peut modifier les performances de classification. Ainsi, la Section 5.3.1.1 montre qu'on obtient les résultats les plus forts des classifications de l'année complète 2018 pour les trois légendes si l'on considère les FS. Cependant, l'analyse des K révèle que les meilleurs résultats sont généralement obtenus pour les légendes à 5 et 9 classes. Bien que les résultats soient moins bons pour la légende à 12 classes, ils ne sont pas non plus meilleurs en fusionnant les classes d'OCS en présence ici de la combinaison d'images optiques et radar.

5.3.1.6.2 Influence de la dimension temporelle des données satellitaires sur les classifications supervisées de la zone d'intérêt T33PUL La dimension temporelle des images satellitaires (mensuelles ou annuelle) peut également jouer un rôle important dans l'amélioration des performances de classification. Ainsi, la Section 5.3.1.1 montre qu'on obtient les résultats les plus forts pour les trois légendes selon les FS et pour les légendes à 5 et 9 classes selon les K, de la classification de la série annuelle (2018) complète. Bien que les résultats des classifications mensuelles soient moins bons, les classifications du mois de septembre et celle de l'année complète 2018 sont proches.

<i>L1-L2A</i>	jan.	fév.	mar.	avr.	mai	juil.	août.	sept.	oct.	nov.	déc.	2018	VT
janvier	0.00	0.21	0.25	0.27	0.34	0.32	0.37	0.35	0.24	0.21	0.26	0.32	0.33
février	0.21	0.00	0.29	0.25	0.34	0.28	0.38	0.35	0.26	0.25	0.25	0.31	0.39
mars	0.25	0.29	0.00	0.27	0.38	0.33	0.39	0.37	0.30	0.28	0.32	0.26	0.28
avril	0.27	0.25	0.27	0.00	0.37	0.30	0.39	0.37	0.28	0.27	0.29	0.27	0.33
mai	0.34	0.34	0.38	0.37	0.00	0.35	0.43	0.41	0.37	0.34	0.40	0.36	0.45
juin	0.32	0.28	0.33	0.30	0.35	0.00	0.43	0.35	0.34	0.30	0.33	0.29	0.39
juillet	0.37	0.38	0.39	0.39	0.43	0.43	0.00	0.43	0.34	0.36	0.36	0.45	0.49
août	0.61	0.60	0.68	0.67	0.67	0.67	0.58	0.63	0.61	0.60	0.60	0.74	0.85
septembre	0.35	0.35	0.37	0.37	0.41	0.35	0.43	0.00	0.35	0.32	0.34	0.42	0.48
octobre	0.24	0.26	0.30	0.28	0.37	0.34	0.34	0.35	0.00	0.18	0.26	0.34	0.35
novembre	0.21	0.25	0.28	0.27	0.34	0.30	0.36	0.32	0.18	0.00	0.25	0.31	0.35
décembre	0.26	0.25	0.32	0.29	0.40	0.33	0.36	0.34	0.26	0.25	0.00	0.37	0.41
2018	0.32	0.31	0.26	0.27	0.36	0.29	0.45	0.42	0.34	0.31	0.37	0.00	0.26
VT	0.33	0.39	0.28	0.33	0.45	0.39	0.49	0.48	0.35	0.35	0.41	0.26	0.00

TAB. 5.5 – Moyennes des distances entre les histogrammes calculées au sein de cellules de taille 200 pixels extraites des classifications mensuelles et annuelle de séries temporelles d'images optiques et radar Sentinel-1 *L1/-2_L2A* et de la vérité terrain (*VT*) avec la légende à 9 classes, de la zone d'intérêt *T33PUL*.

5.3.2 Zone d'intérêt T32NPL (ZONE2, Ouest-Centre)

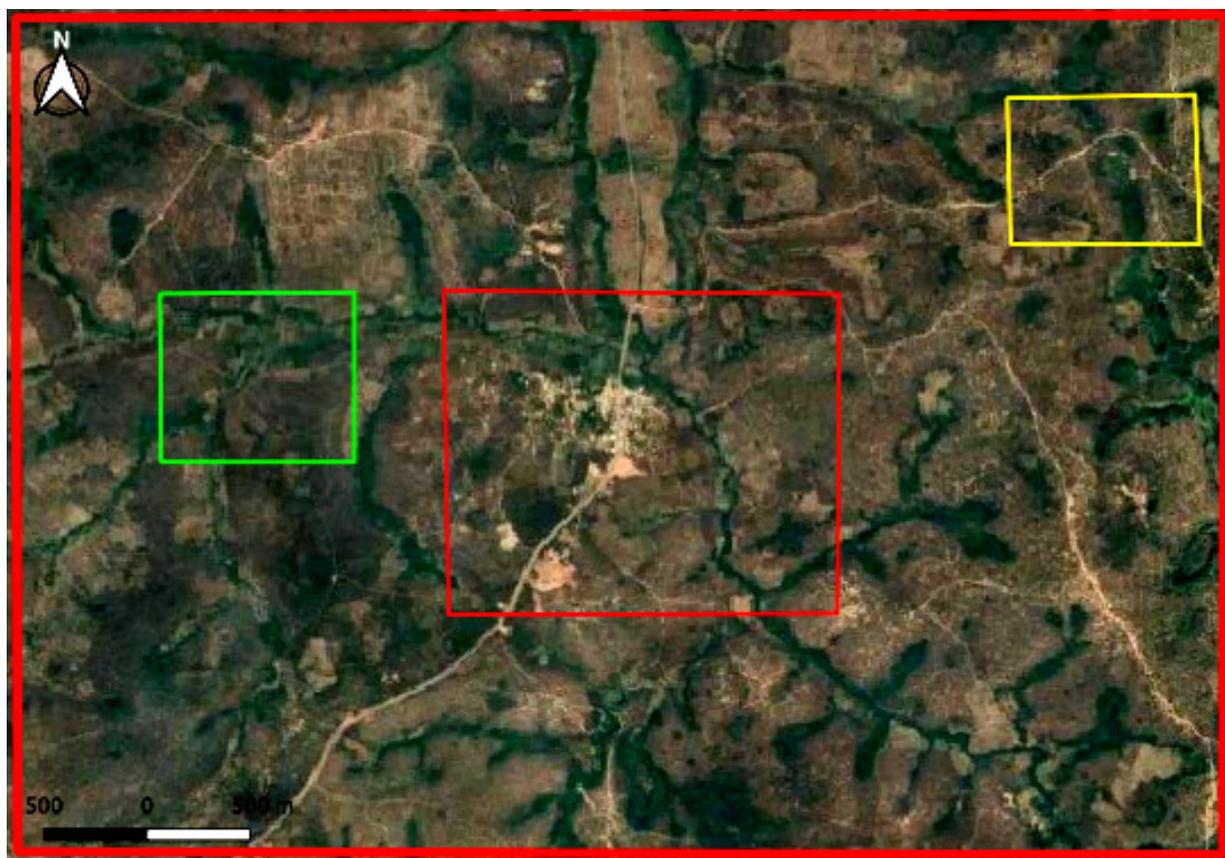
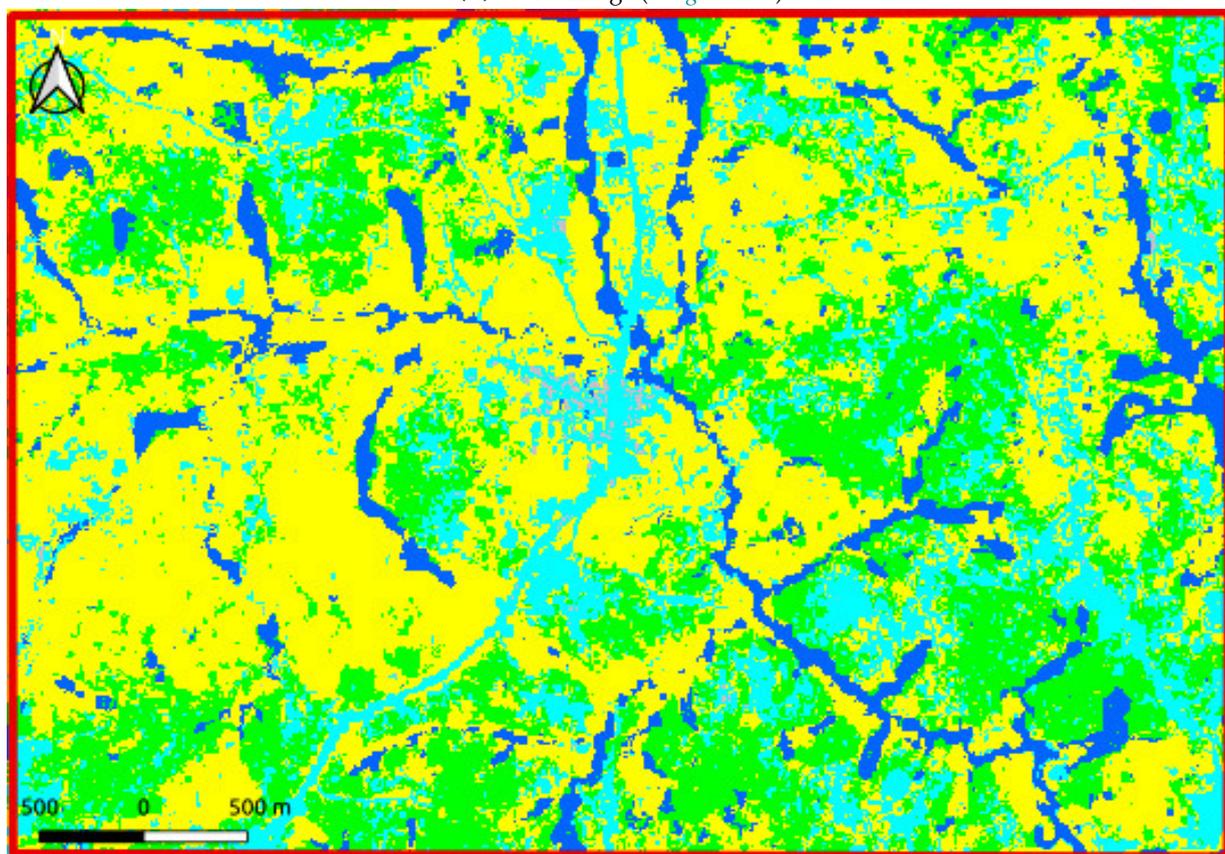
Les extraits d'ortho-image et des différentes classifications supervisées de séries temporelles d'images optiques et radar Sentinel-1_L1/-2_L2A de l'année complète 2018 pour les légendes à 5, 9 et 12 classes, de la zone d'intérêt T32NPL sont présentées dans les Figures 5.14B, 5.15A et 5.15B respectivement.

5.3.2.1 Evaluation quantitative des classifications supervisées de la zone d'intérêt T32NPL

Les Figures 5.16 et 5.17 présentent respectivement les métriques de qualité globale - F-Scores moyens (FS) et coefficients Kappa (K) des classifications supervisées de séries temporelles d'images optiques et radar Sentinel-1_L1/-2_L2A des mois et de l'année complète 2018 pour les trois légendes. Quelle que soit la légende utilisée dans les classifications de la combinaison d'images optiques et radar, les valeurs de FS et de K sont toujours variables et faibles ($0,09 < FS < 0,45$) et ($0,23 < K < 0,31$). **Les résultats les plus forts sont associés à la classification de l'année complète pour les trois légendes si l'on considère les FS et les K.** Au contraire, les résultats les plus faibles sont associés aux classifications des mois d'avril pour la légende à 9 classes et d'août pour les légendes à 5 et 12 classes si l'on considère les FS et aux classifications du mois d'août pour les trois légendes si l'on considère les K. Ces résultats sont en accord avec ceux obtenus dans la littérature, qui montrent l'apport de la combinaison d'images optiques et radar dans la cartographie des classes difficiles comme les classes VNC; VHB; FOU et FFE pour la légende à 12 classes qui apparaissent ici, davantage détectées et mieux discriminées.

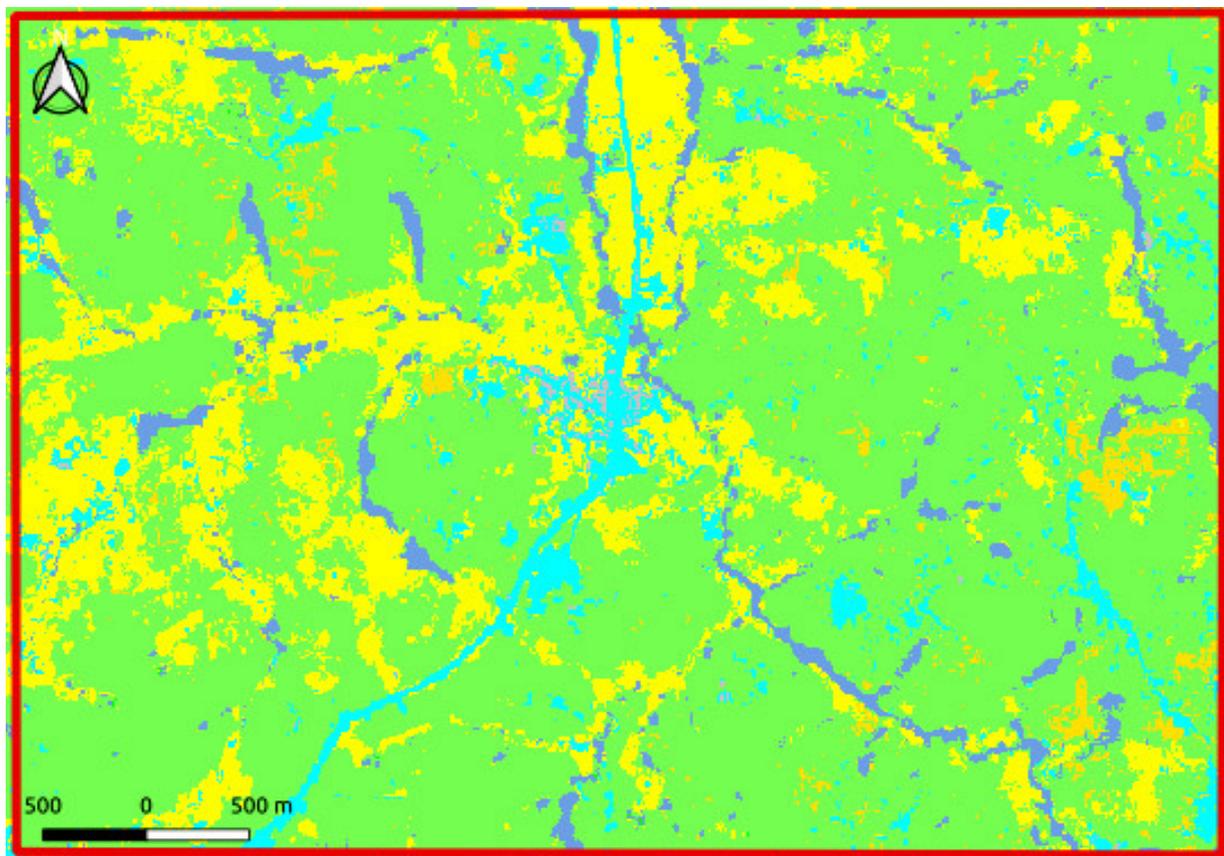
Les Figures 5.18, 5.19 et 5.20 présentent les métriques de qualité par classe - F-Score (FS/classe), précision utilisateur (PU) et précision producteur (PP) des classifications supervisées de séries temporelles d'images optiques et radar Sentinel-1_L1/-2_L2A des mois et de l'année complète 2018 pour les légendes à 5 et 9 et 12 classes respectivement. L'utilisation des légendes à 5 et 9 classes permet d'améliorer la classification annuelle des cinq classes EAU (FS (EAU) $\simeq 0,09$); RTE (FS (RTE) $\simeq 0,2$); BTM (FS (BTM) $\simeq 0,51$); AGR (FS (AGR) $\simeq 0,54$) et VGT (FS (VGT) $\simeq 0,89$) de la légende à 5 classes puis des classes ZHU (FS (ZHU) $\simeq 0,08$); PRA (FS (PRA) $\simeq 0,03$); RTE (FS (RTE) $\simeq 0,19$); BTM (FS (BTM) $\simeq 0,49$); ARB (FS (ARB) $\simeq 0,55$) et AGR (FS (AGR) $\simeq 0,59$) pour la légende à 9 classes. De plus, les classes SFE (FS (SFE) $\simeq 0,04$) et RIV (FS (RIV) $\simeq 0,07$) sont améliorées dans la classification du mois de janvier tandis que la classe FRT (FS (FRT) $\simeq 0,93$) est améliorée dans la classification du mois d'avril pour la légende à 9 classes. L'utilisation de la légende à 12 classes permet également d'améliorer les classifications mensuelles et annuelle des douze classes particulièrement des classes VNC; VHB; FOU; FFE; TCU; ARB et ZHH. **Les meilleurs résultats sont alors obtenus pour la légende à 9 classes, où le FS/classe atteint le FS (FRT) $\simeq 0,93$ de la classe FRT dans la classification du mois d'avril et les précisions PU et PP atteignent respectivement la PU (FRT) $\simeq 0,97$ de la classe FRT dans la classification du mois de janvier et la PP (FRT) $\simeq 0,84$ de la classe FRT dans la classification du mois d'octobre.**

La fusion des trois BDs de la légende à 12 classes, offre également de bonnes performances à l'ensemble des classifications mensuelles et annuelle. Par contre, ces classifications sont de moins bonne qualité pour la majorité des mois comparativement à celles correspondant aux légendes à 5 et 9 classes. Ce résultat montre que l'ajout de BDs dégrade les performances des classifications mensuelles. C'est ainsi que **toutes les classes sont assez moins détectées dans la classification du mois d'août pour la légende à 12 classes.** Par conséquent, il serait plus judicieux d'effectuer la fusion précoce de l'ensemble des séries mensuelles dans la classification d'un nombre élevé de classes d'OCS.

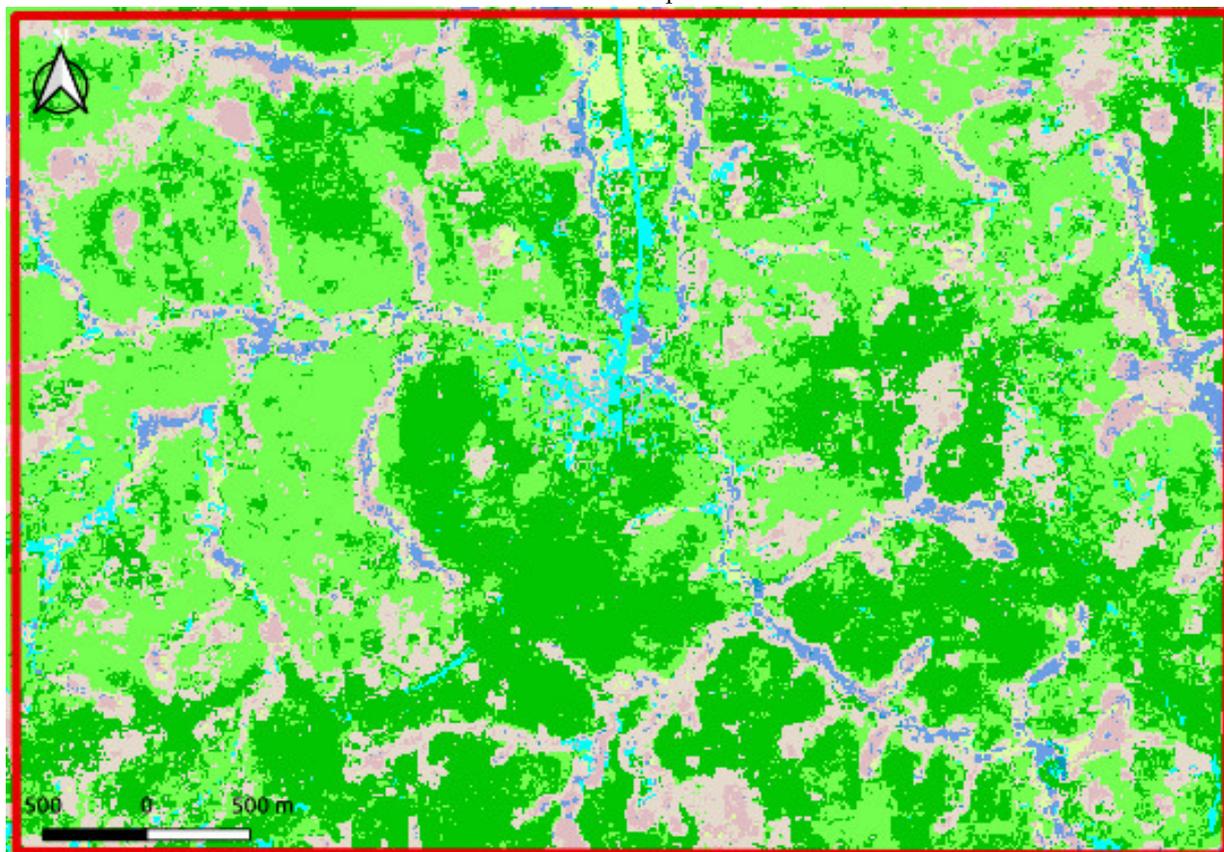
(A) Ortho-image (*Google Earth*)

(B) Classification de l'année complète 2018 avec 5 classes

FIG. 5.14 – Extraits de l'ortho-image et de la classification supervisée de séries temporelles d'images optiques et radar Sentinel-1_L1/-2_L2A avec la légende à 5 classes :
 ■ : VGT; ■ : AGR; ■ : EAU; ■ : RTE; ■ : BTM, de la zone d'intérêt T32NPL.



(A) Classification de l'année complète 2018 avec 9 classes



(B) Classification de l'année complète 2018 avec 12 classes

FIG. 5.15 – Extraits des classifications supervisées d'images Sentinel-1_L1/-2_L2A avec les légendes à 9 : ■ : FRT; ■ : PRA; ■ : ARB; ■ : AGR; ■ : SFE; ■ : ZHU; ■ : RIV; ■ : RTE; ■ : BTM et 12 : ■ : VNC; ■ : VHB; ■ : FOU; ■ : FFE; ■ : TCU; ■ : ARB; ■ : ZHH; ■ : SFE; ■ : ZHU; ■ : RIV; ■ : RTE; ■ : BTM classes, de la zone T32NPL.

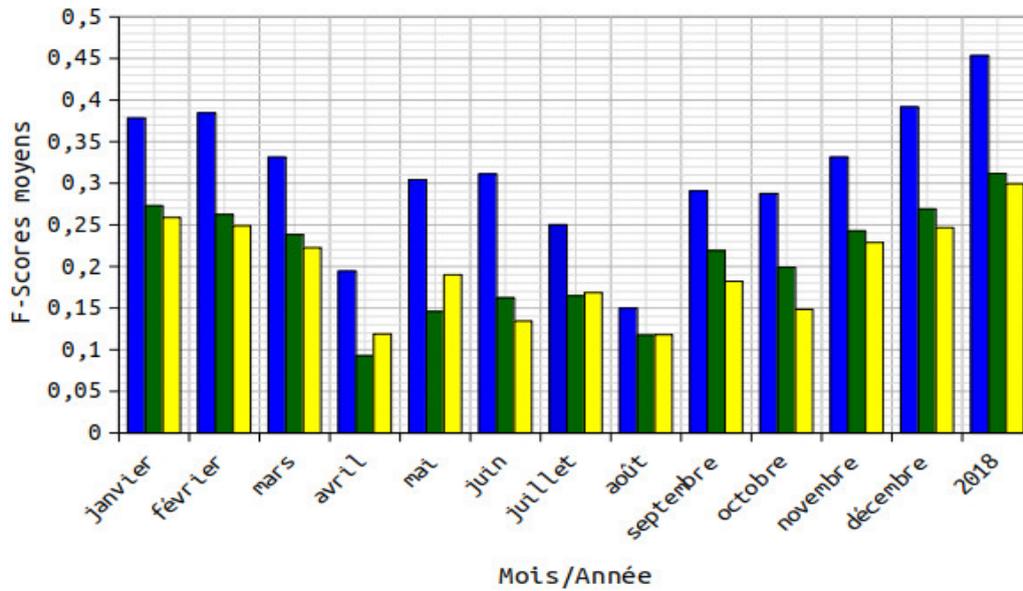


FIG. 5.16 – F-Scores moyens des classifications supervisées de séries d’images Sentinel-1_L1/-2_L2A avec les légendes à 5 et 9 et 12 classes, de la zone d’intérêt T32NPL.

La fusion des classes FRT ; PRA et ARB dans la légende à 9 classes en classe VGT de la légende à 5 classes offre des résultats contrastés. En effet, l’utilisation de la classe VGT diminue les performances de la classification annuelle ($FS = 0,96$; $PU(VGT) \simeq 0,97$) pour la légende à 5 classes, alors que le FS est de 1 lorsque les classes FRT ; PRA et ARB sont considérées indépendamment ($PU(FRT) \simeq 0,95$; $PU(PRA) \simeq 0,05$ et $PU(ARB) \simeq 0,48$) pour la légende à 9 classes. Les valeurs de FS et de PU restent cependant de moins bonne qualité dans la classification annuelle avec les images optiques et radar. **La fusion des classes FRT ; PRA et ARB n’est donc pas un choix suffisant et pertinent en raison des faibles valeurs de FS de la classification annuelle pour la légende à 5 classes.** Dans ce cas, la fusion des classes d’OCS induit davantage de bruit que d’étiquette utile dans la combinaison d’images optiques et radar Sentinel-1_L1/-2_L2A.

Les très faibles performances des classes (SFE et ZHU) dans les classifications des mois de février à juin utilisant les légendes à 9 et 12 classes sont dues au manque de données de référence concernant cette paire de classe ainsi qu’à la saison sèche qu’il fait pendant ces mois dans cette zone. En effet, **les éléments naturels issus de chacune des classes de la paire, peuvent avoir des réflectances très proches malgré la combinaison d’images optiques et radar durant les mois de février et mars** constituant ainsi une limite dans les classifications mais également pour l’obtention préalable de données de référence. De différentes classes d’OCS qui se ressemblent peuvent être regroupées dans une seule classe et une classe hétérogène peut correspondre à plusieurs autres classes d’OCS. Ces limites peuvent impacter les résultats globaux mais également les confusions.

Afin de permettre l’analyse détaillée par paire de classes **des erreurs de classification utilisant la stratégie STR1 avec la combinaison d’images optiques et radar par rapport à celles se fondant sur les images optiques seules**, les Tableaux 5.6, 5.7 et 5.8 montrent les matrices de confusion utilisant respectivement les légendes à 5, 9 et 12 classes sur la zone d’intérêt T32NPL. Des confusions existent toujours entre les classes lorsque l’on utilise les données optiques et radar pour les trois légendes.

Dans ces Tableaux, les pixels identifiés en classe VGT se trouvent moins classifiés en AGR et le taux de FP, avec la classe AGR, baisse ici de 15,7% à 10,2% avec l’utilisation de la combinaison de séries

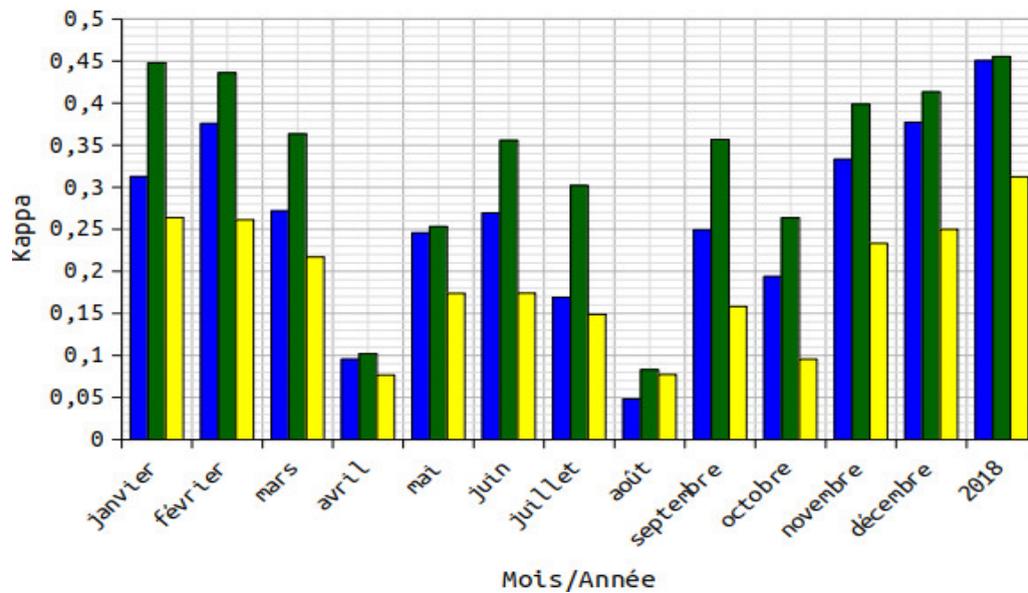


FIG. 5.17 – Coefficients Kappa des mêmes classifications que les FS dans la Figure 5.16.

d'images optiques Sentinel-2 et radar Sentinel-1 pour la légende à 5 classes. La confusion s'atténue également avec l'utilisation des classes FRT et ARB et les taux de *FP* baissent de 9,2% à 8,7% pour la classe FRT et de 20% à 15,5% pour la classe ARB. Par contre, la confusion s'accroît plutôt grandement avec l'utilisation de la classe PRA, et le taux de *FP* augmente de 2% à 10,1%. Concernant la confusion avec la classe EAU, elle s'atténue et le taux de *FP* baisse pour la légende à 5 classes de même que pour la classe ZHU (de 36,1% à 27,5%) de la légende à 9 classes. De plus, cette confusion s'atténue toujours avec l'ajout de nouvelles classes pour la légende à 12 classes. C'est ainsi que **la confusion entre les classes VNC et RIV reste fortement atténuée. Cette diminution de *FP* se fait au détriment des *FN*, avec une forte augmentation de ceux-ci lors de l'utilisation de la combinaison d'images optiques et radar.**

Par ailleurs, avec la combinaison d'images optiques et radar Sentinel-1_L1/-2_L2A pour la légende à 5 classes sur la zone d'intérêt T32NPL, la classe RTE est classifiée en AGR avec un taux de *FP*=20,1%. À l'inverse, la classe AGR est classifiée en RTE avec un taux inférieur de *FN*=14%. Ce taux baisse encore à *FN*=12,9% de même que le taux de *FP* qui devient *FP*=18,4% et la confusion s'atténue donc pour la légende à 9 classes. De plus, pour cette légende, les classes SFE et RIV sont classifiées en RTE et ARB avec des taux de *FP*=1% et *FP*=8% respectivement. Inversement, les classes RTE et ARB sont classifiées en SFE et RIV avec des taux très inférieurs de *FN*=0% et *FN*=12,5%. Ces taux restent constants ou baissent encore à *FN*=0% et *FN*=0,4% de même que les taux de *FP* qui deviennent respectivement *FP*=13,7% et *FP*=1% et les confusions s'atténuent donc pour la légende à 12 classes. En outre, pour la légende à 9 classes, la classe RTE est classifiée en RIV avec un faible taux de *FP*=2,1%. À l'inverse, la classe RIV est classifiée en RTE avec un taux légèrement supérieur de *FN*=2,8%. Ce taux augmente à *FN*=2,9% de même que le taux de *FP* qui devient *FP*=4,4% et la confusion s'accroît pour la légende à 12 classes. En général, **les taux de *FN* augmentent et la discrimination des classes d'OCS est ici meilleure à quelques exceptions près telles que les classes RTE et RIV dont la confusion demeure en utilisant la combinaison d'images optiques et radar Sentinel-1_L1/-2_L2A pour les légendes à 9 et 12 classes.**

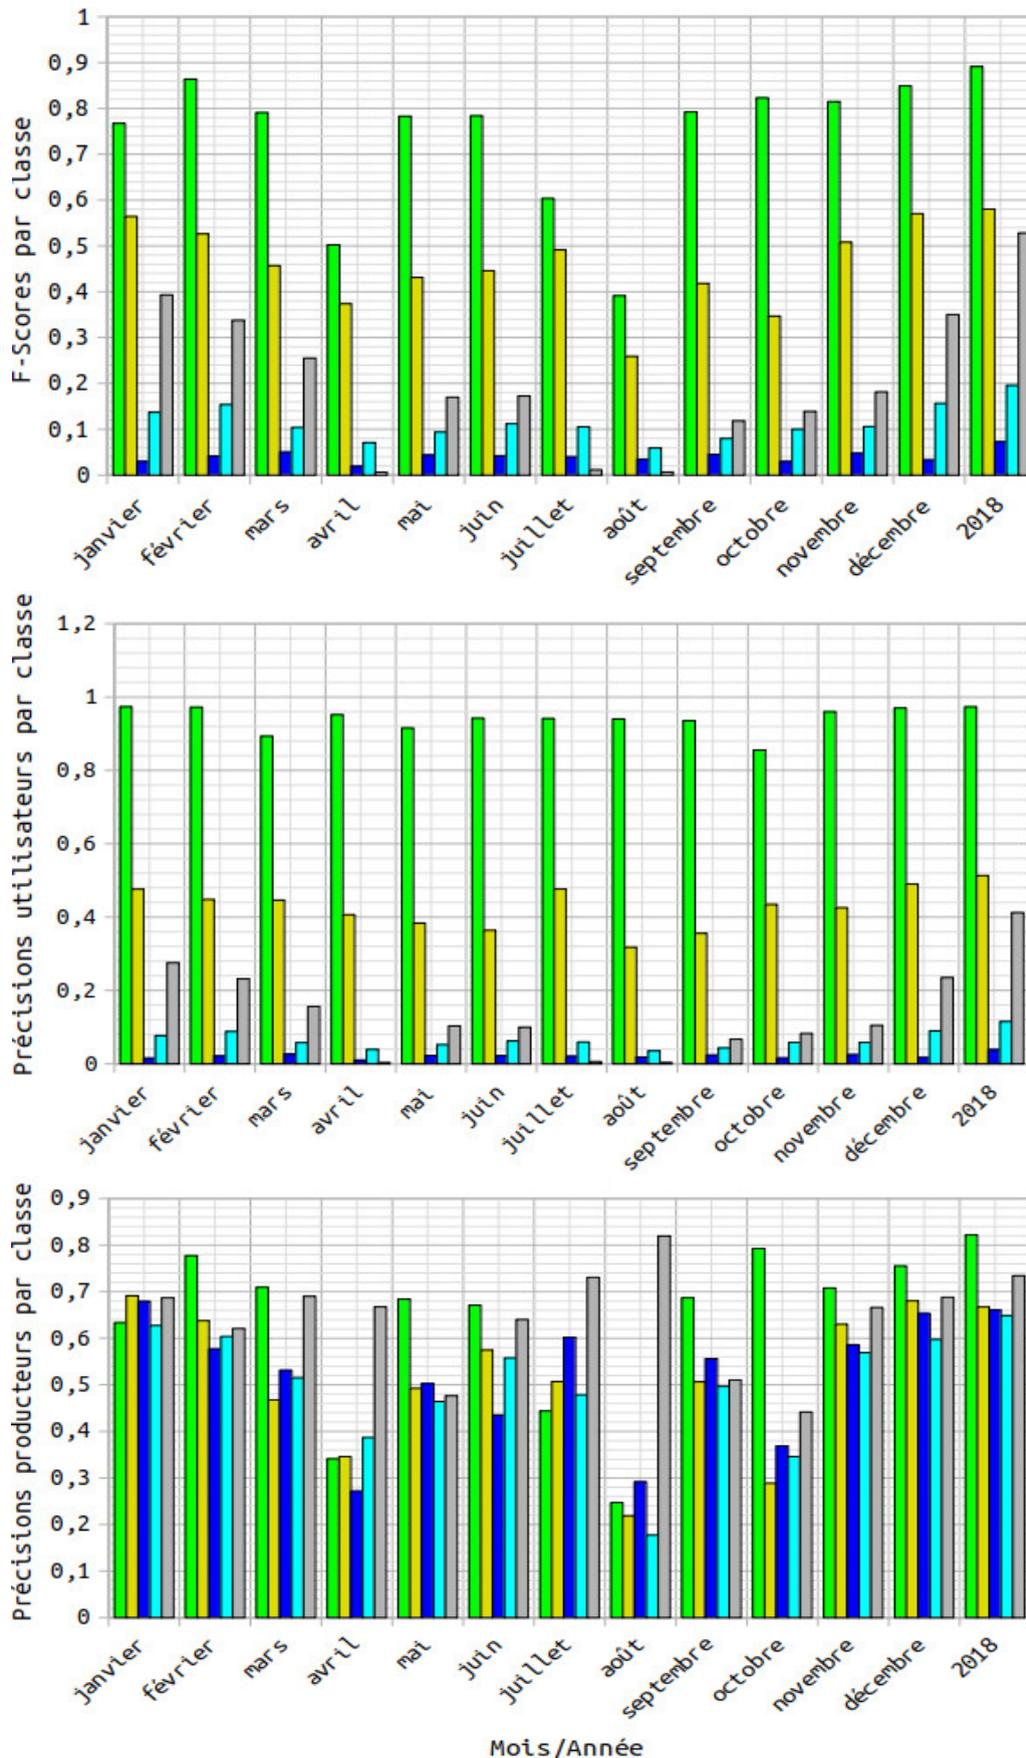


FIG. 5.18 – F-Scores et précision utilisateur et précision producteur par classe des classifications supervisées de séries d'images Sentinel-1_L1/-2_L2A avec la légende à 5 classes : ■ : VGT; ■ : AGR; ■ : EAU; ■ : RTE; ■ : BTM, de la zone d'intérêt T32NPL.

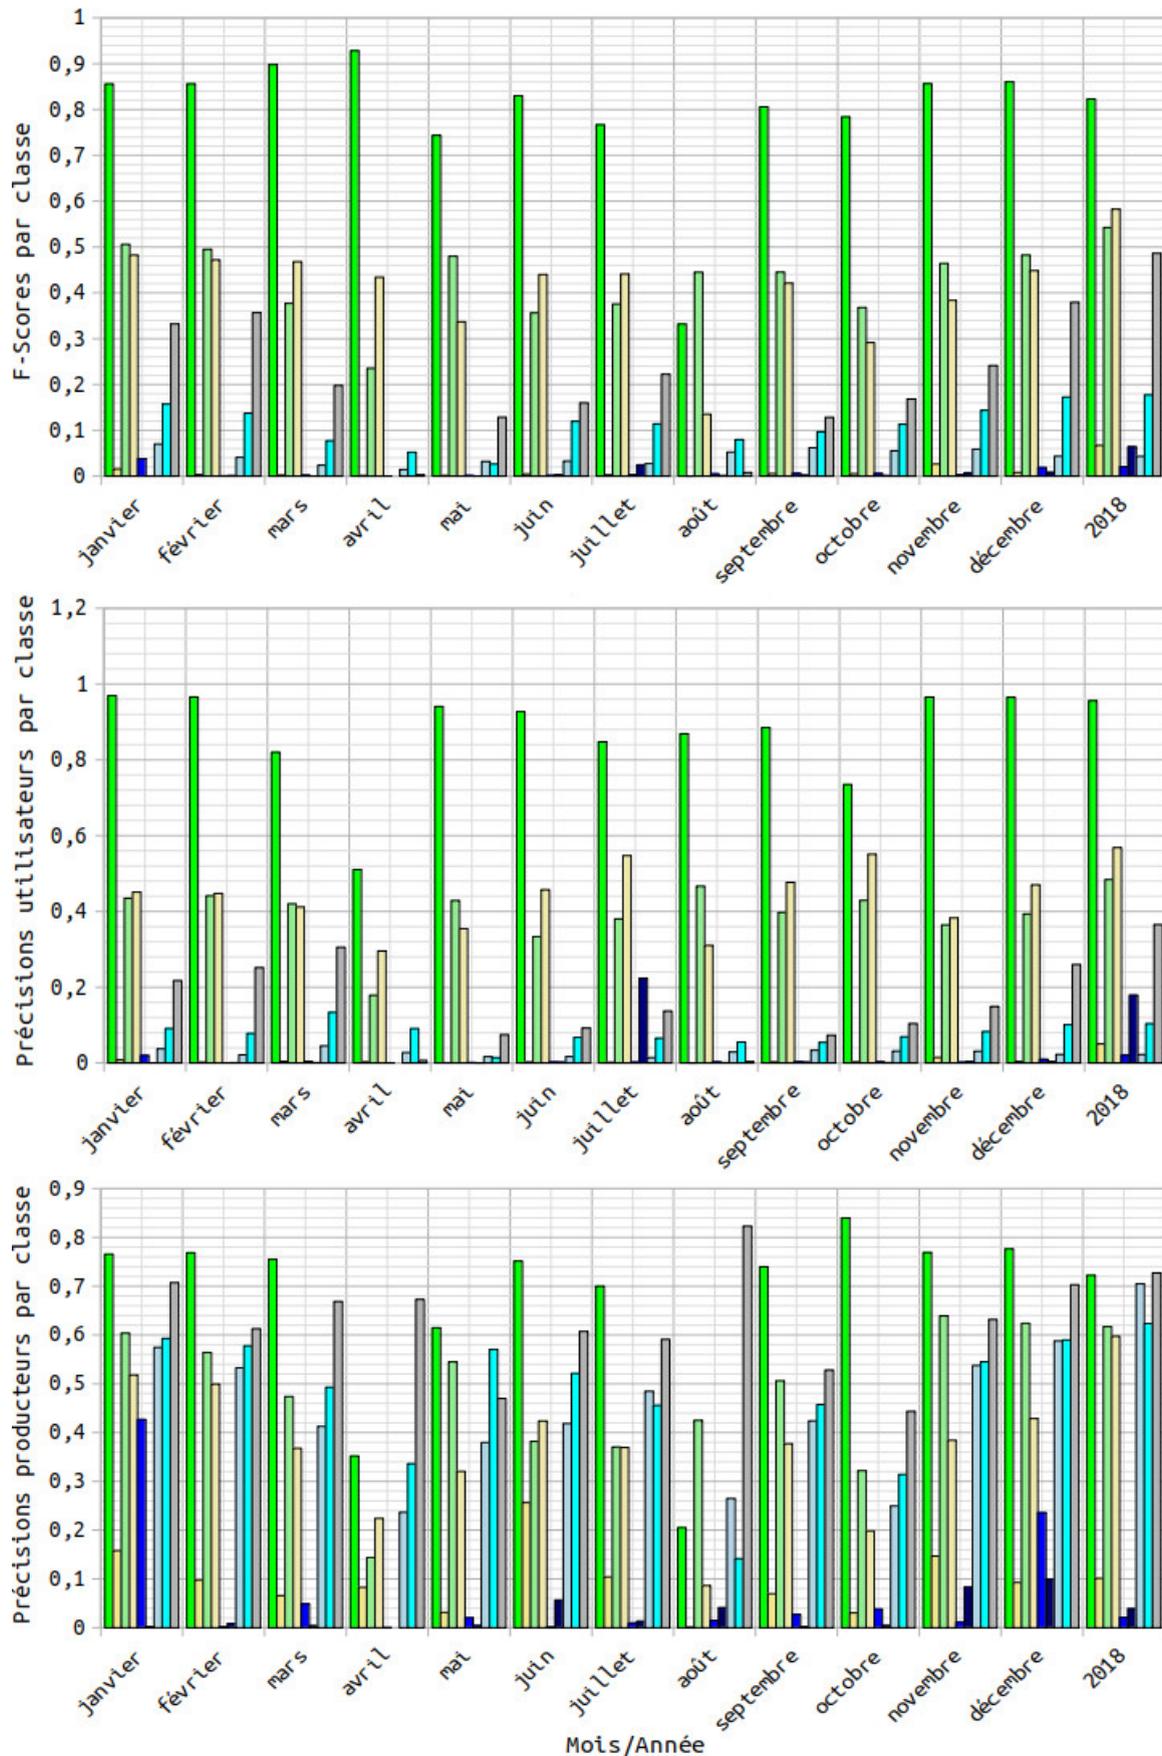


FIG. 5.19 – F-Scores et précision utilisateur et précision producteur par classe des classifications supervisées de séries d’images Sentinel-1_L1/-2_L2A avec la légende à 9 classes : ■ : FRT ; ■ : PRA ; ■ : ARB ; ■ : AGR ; ■ : SFE ; ■ : ZHU ; ■ : RIV ; ■ : RTE ; ■ : BTM, de la zone d’intérêt T32NPL.

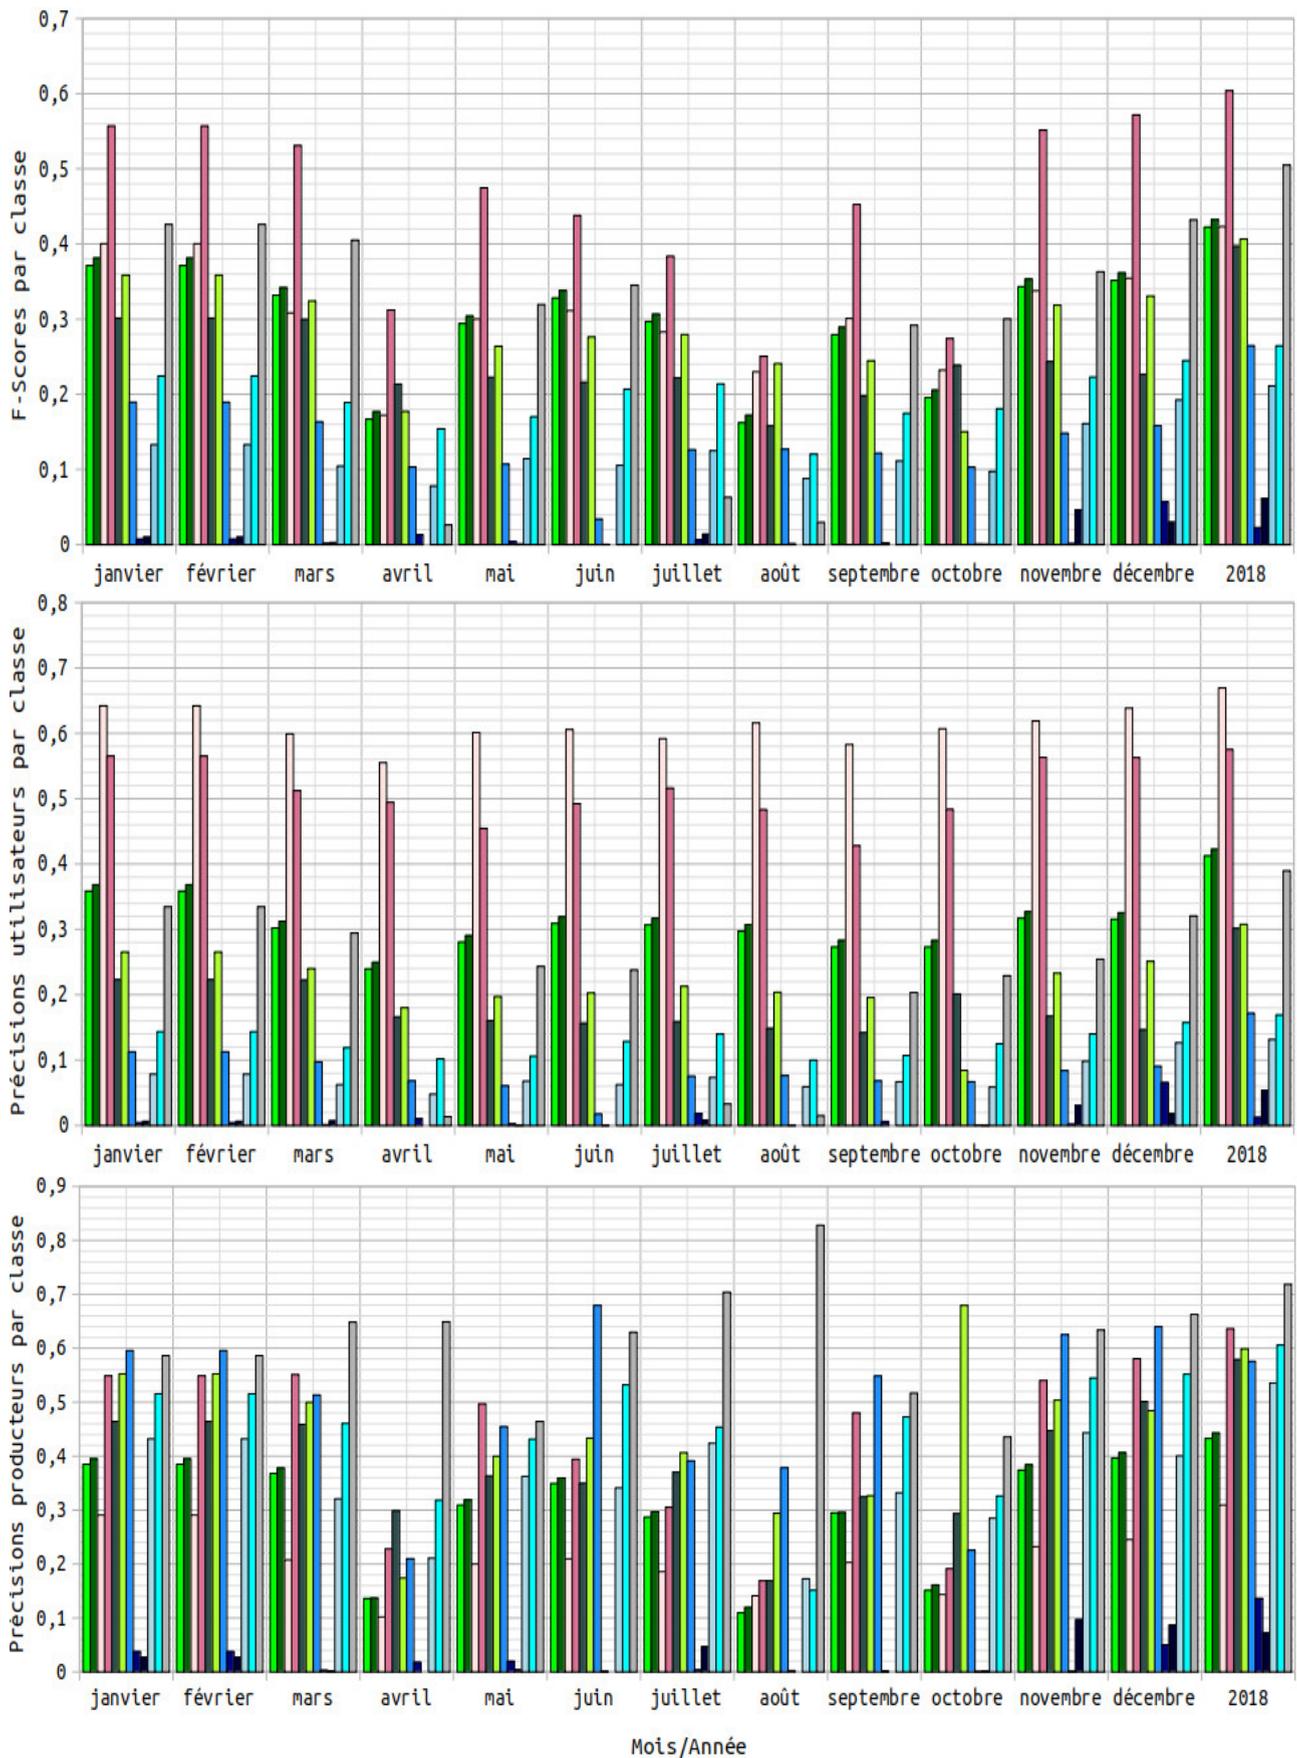


FIG. 5.20 – F-Scores et précision utilisateur et précision producteur par classe des classifications supervisées de séries d’images Sentinel-1_L1/-2_L2A avec la légende à 12 classes : ■ : VNC; ■ : VHB; ■ : FOU; ■ : FFE; ■ : TCU; ■ : ARB; ■ : ZHH; ■ : SFE; ■ : ZHU; ■ : RIV; ■ : RTE; ■ : BTM, de la zone d’intérêt T32NPL.

Les confusions qui impliquent la classe EAU (RTE et RIV) s'expliquent par la séparabilité de cette dernière qui serait liée à la diffusion inhérente à sa constitution. En effet, dans les hyperfréquences, en saison de pluies, la classe RTE contribuerait moins à la rétrodiffusion du signal, et il y aurait plus d'impact de la structure de l'eau. Les synthèses de séries temporelles d'images optiques Sentinel-2_L3A pourraient permettre de prendre en compte la structure de la classe RTE, et de s'affranchir de ces confusions. **La complémentarité entre les synthèses de séries d'images optiques et les images radar devraient permettre de réduire davantage les confusions entre les classes RTE et RIV.**

TAB. 5.6 – Matrice de confusion avec la légende à 5 classes.

L1-L2A		Vérité Terrain					PU
% VU	CL	VGT	AGR	EAU	RTE	BTM	
73,1	VGT	82,2	13,0	20,9	6,9	2,1	97,3
11,4	AGR	10,2	66,7	10,0	20,1	3,5	51,3
0,1	EAU	6,0	5,3	66,1	2,6	0,5	3,8
0,1	RTE	1,5	14,0	2,9	64,9	20,6	11,5
0,1	BTM	0,1	1,0	1,7	5,5	73,4	41,2
	PP	82,2	66,7	66,1	64,9	73,4	

TAB. 5.7 – Matrice de confusion avec la légende à 9 classes.

L1-L2A		Vérité Terrain									PU
% VU	CL	FRT	PRA	ARB	AGR	SFE	ZHU	RIV	RTE	BTM	
65,5	FRT	72,2	0,9	5,2	10,1	0,3	3,9	12,0	7,1	1,9	95,6
0,1	PRA	0,1	41,3	0,2	0,1	0,0	0,0	0,0	0,1	0,0	5,0
7,5	ARB	6,0	38,8	61,7	12,7	1,1	0,3	8,0	4,8	0,7	48,4
11,4	AGR	8,7	10,1	15,5	59,7	6,9	27,5	6,6	18,4	3,2	56,8
0,1	SFE	0,0	0,0	0,0	0,0	88,5	0,0	0,0	0,0	0,0	2,0
0,1	ZHU	0,0	0,0	0,0	0,0	0,0	54,3	0,0	0,0	0,0	17,9
0,1	RIV	12,0	0,8	12,5	3,3	2,1	12,7	70,5	2,1	0,3	2,2
0,1	RTE	0,9	6,8	4,6	12,9	1,0	0,1	2,8	62,4	21,1	10,3
0,1	BTM	0,1	1,2	0,3	1,1	0,1	1,2	0,2	5,2	72,7	36,5
	PP	72,2	41,3	61,7	59,7	88,5	54,3	70,5	62,4	72,7	

TAB. 5.8 – Matrice de confusion avec la légende à 12 classes.

L1-L2A		Vérité Terrain											PU	
% VU	CL	VNC	VHB	FOU	FFE	TCU	ARB	ZHH	SFE	ZHU	RIV	RTE		BTM
0,1	VNC	90,2	0,0	0,0	0,0	0,0	0,0	0,0	0,0	0,0	0,0	0,0	0,0	41,3
3,1	VHB	0,1	44,3	10,7	1,2	3,5	21,4	2,9	0,8	0,0	0,6	2,0	0,2	42,3
1,1	FOU	0,1	14,6	30,9	16,2	8,3	8,7	3,9	6,6	0,5	5,1	5,5	0,8	66,9
1,0	FFE	0,1	7,5	23,7	63,6	5,7	2,2	2,0	19,1	7,2	17,4	12,2	2,6	57,5
1,6	TCU	0,1	2,8	6,4	3,3	57,9	1,0	0,1	0,3	0,0	4,1	8,3	3,9	30,2
0,2	ARB	0,1	20,2	11,9	1,0	4,8	59,9	0,8	0,0	0,0	1,0	1,9	0,4	30,8
0,1	ZHH	0,1	0,6	0,3	0,3	0,1	0,1	57,5	2,0	2,4	14,2	0,0	0,0	17,2
0,1	SFE	0,3	1,0	0,0	0,1	0,0	0,0	0,8	43,4	0,0	0,9	0,0	0,0	1,2
0,1	ZHU	0,1	0,0	0,0	0,0	0,0	0,0	0,5	0,0	57,5	0,1	0,0	0,0	5,4
0,1	RIV	0,1	1,3	4,4	8,6	3,0	0,4	22,7	13,6	31,8	53,6	4,4	0,5	13,2
0,1	RTE	0,3	7,9	10,5	5,2	12,7	5,6	1,4	13,7	0,6	2,9	60,6	19,9	16,9
0,1	BTM	0,0	0,8	1,2	0,4	4,2	0,8	0,1	0,5	0,0	0,1	5,2	71,8	38,9
	PP	90,2	44,3	30,9	63,6	57,9	59,9	57,5	43,4	57,5	53,6	60,6	71,8	

% VU : pourcentage de données vecteurs utilisées.

CL : classification.

5.3.2.2 Utilisation des confiances des classifications supervisées de la zone d'intérêt T32NPL

Les Figures 5.21A, 5.21B et 5.22 montrent les extraits de cartes de confiance obtenues correspondantes aux extraits de classifications supervisées de la zone d'intérêt T32NPL dans les Figures 5.14B, 5.15A et

5.15B pour les légendes à 5, 9 et 12 classes respectivement.

Étant donné que la confiance dépend non seulement du nombre de dates pour lesquelles chaque pixel est valide, mais également de la légende, on peut voir identiquement à la zone d'intérêt *T33PUL* que **les valeurs de confiance diminuent globalement lorsque le nombre de classes augmente. Par contre, la confiance se trouve renforcée localement lorsque le nombre de classes augmente comme c'est le cas pour la légende à 12 classes.** Toutefois, l'effet de la présence d'une importante quantité de nuages et leurs ombres sur la zone d'intérêt *T32NPL* rend les classes d'OCS des légendes à 9 et 12 classes difficilement reconnaissables dans la partie ouest des Figures 5.21B et 5.22.

5.3.2.3 Evaluation qualitative des classifications supervisées de la zone d'intérêt *T32NPL*

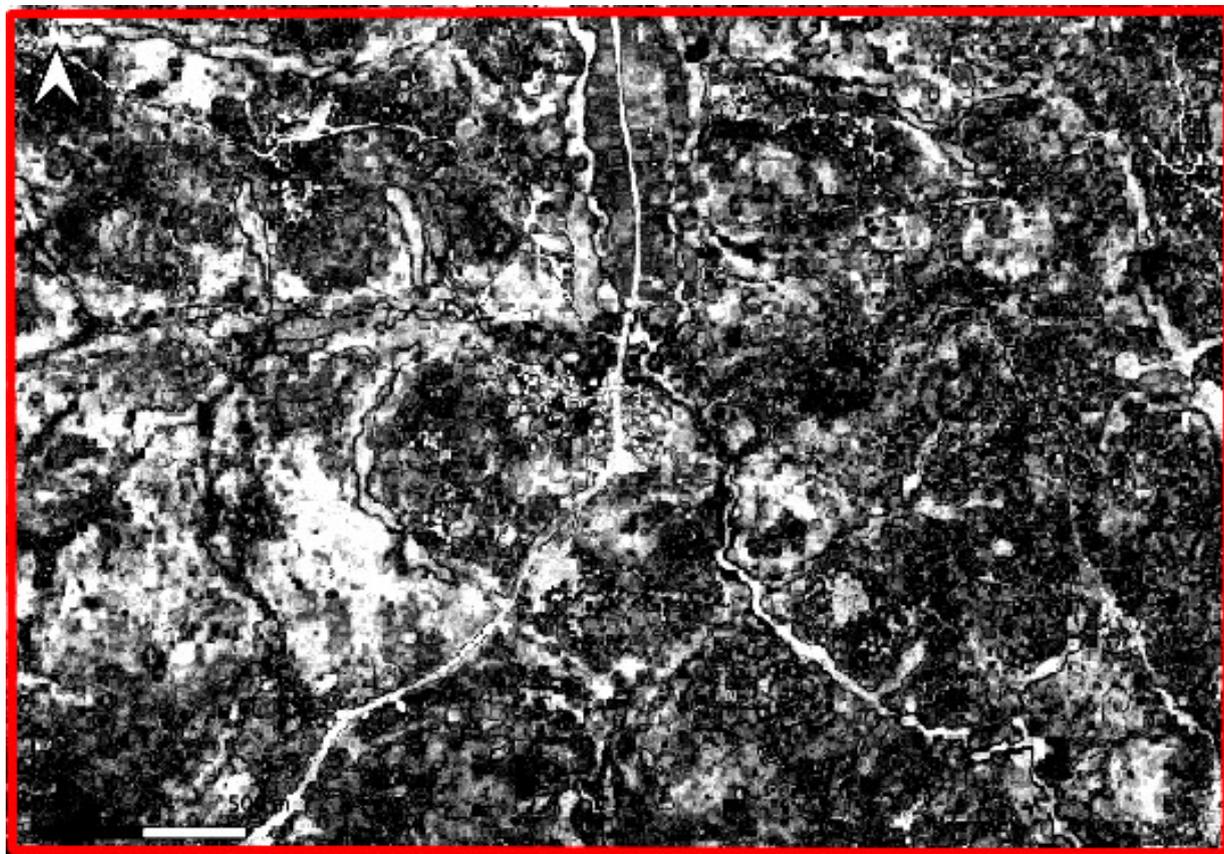
De manière similaire à la zone d'intérêt *T33PUL*, une évaluation visuelle permet d'analyser différents problèmes identifiés sur la zone d'intérêt *T32NPL*.

5.3.2.3.1 Paysages difficiles dans les classifications supervisées de la zone d'intérêt *T32NPL* Les métriques quantitatives ne pouvant permettre de déceler tous les types d'erreurs présentes dans les classifications de grandes étendues, l'étude qualitative comparative visuelle des classifications pour les trois légendes est également détaillée dans cette section, sur deux types de zones : **une zone rurale (Figure 5.23) et une zone urbaine (Figure 5.24).**

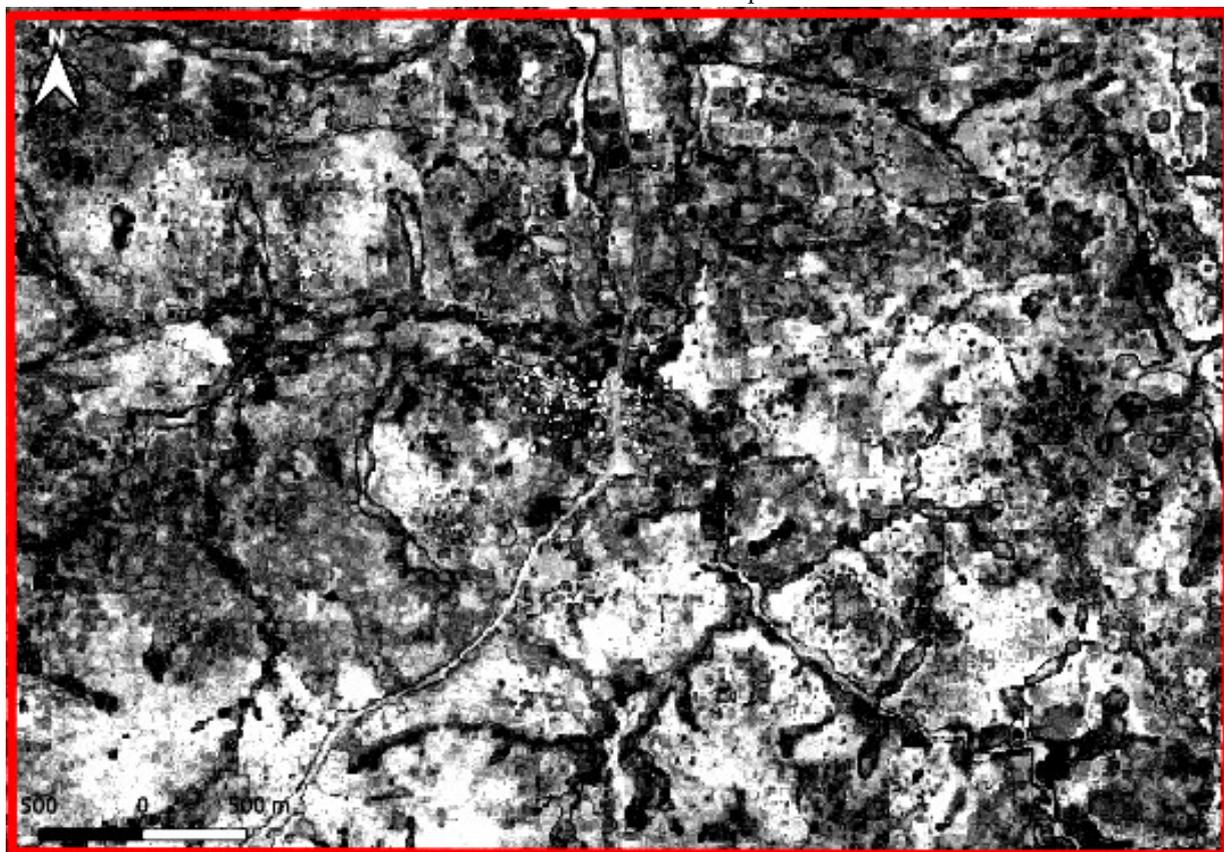
La zone rurale de la Figure 5.23A est la même que celle de la Figure 4.25A. Les différentes classifications et confiances de classification pour les trois légendes sont représentées sur les Figures 5.23B-F. Ici, les différentes classes ne ressortent pas bien pour la légende à 12 classes sur la Figure 5.23D contrairement aux classes d'OCS qui sont assez bien représentées pour les légendes à 5 et 9 classes sur les Figures 5.23B et 5.23C : **la classification ne permet pas d'isoler de manière individuelle les classes de la légende à 12 classes, mais elle permet d'identifier celles des légendes à 5 et 9 classes.** On peut remarquer plusieurs confusions entre les classes pour la légende à 12 classes sur la Figure 5.23D. Pour cette dernière figure, la plupart des classes sont non ou mal représentées. En effet, toutes les classes ne sont pas détectées ou alors s'entremêlent et se confondent lorsqu'elles le sont. Cependant, certaines classes parviennent à être détectées en posant quelques problèmes négligeables. Par exemple, les classes VGT et RTE sont mieux représentées pour la légende à 5 classes (Figure 5.23B). Bien que la classe EAU contient quelques zones d'ombres, elle est assez bien ressortie pour la légende à 5 classes.

La zone urbaine de la Figure 5.24B est la même que celle décrite dans la Figure 4.26B. Pour la légende à 5 classes, la classification de toutes les classes (Figure 5.24A) donne de bons résultats en présentant quelques confusions entre elles du fait de la présence d'échantillons mal étiquetés dans les données d'apprentissage qui dégradent la qualité de la classification. Cependant les classes SFE; ZHU et RIV (Figure 5.24C(D)) de la légende à 9 classes (qui sont contenues dans la classe EAU de la légende à 5 classes) sont plutôt peu détectées, sauf la rivière principale (RIV) qui s'étend du nord au sud et se discriminent assez bien de la classe AGR pour la légende à 9 classes. **Ces pourcentages de détection pourraient davantage s'améliorer en utilisant par exemple les synthèses mensuelles de séries temporelles de la combinaison d'images optiques et radar Sentinel-1_L1/-2_L3A.**

5.3.2.3.2 Petites classes locales sur la zone *T32NPL* Les classes minoritaires sont toujours difficiles à cartographier en raison de leur faible pourcentage lors de l'entraînement des classificateurs. Des exemples typiques sont les classes VNC; VHB; ZHU; RIV; RTE et BTM, concentrées dans des régions bien déterminées. Les Figures 5.25B et 5.25C illustrent comment **les légendes à 9 et 12 classes détectent**



(A) Confiance de la classification de l'année complète 2018 avec 5 classes



(B) Confiance de la classification de l'année complète 2018 avec 9 classes

FIG. 5.21 – Extraits des confiances de classifications supervisées de séries temporelles d'images optiques et radar Sentinel-1_L1/-2_L2A : ■ : faibles → □ : fortes valeurs, de la zone d'intérêt T33PUL.

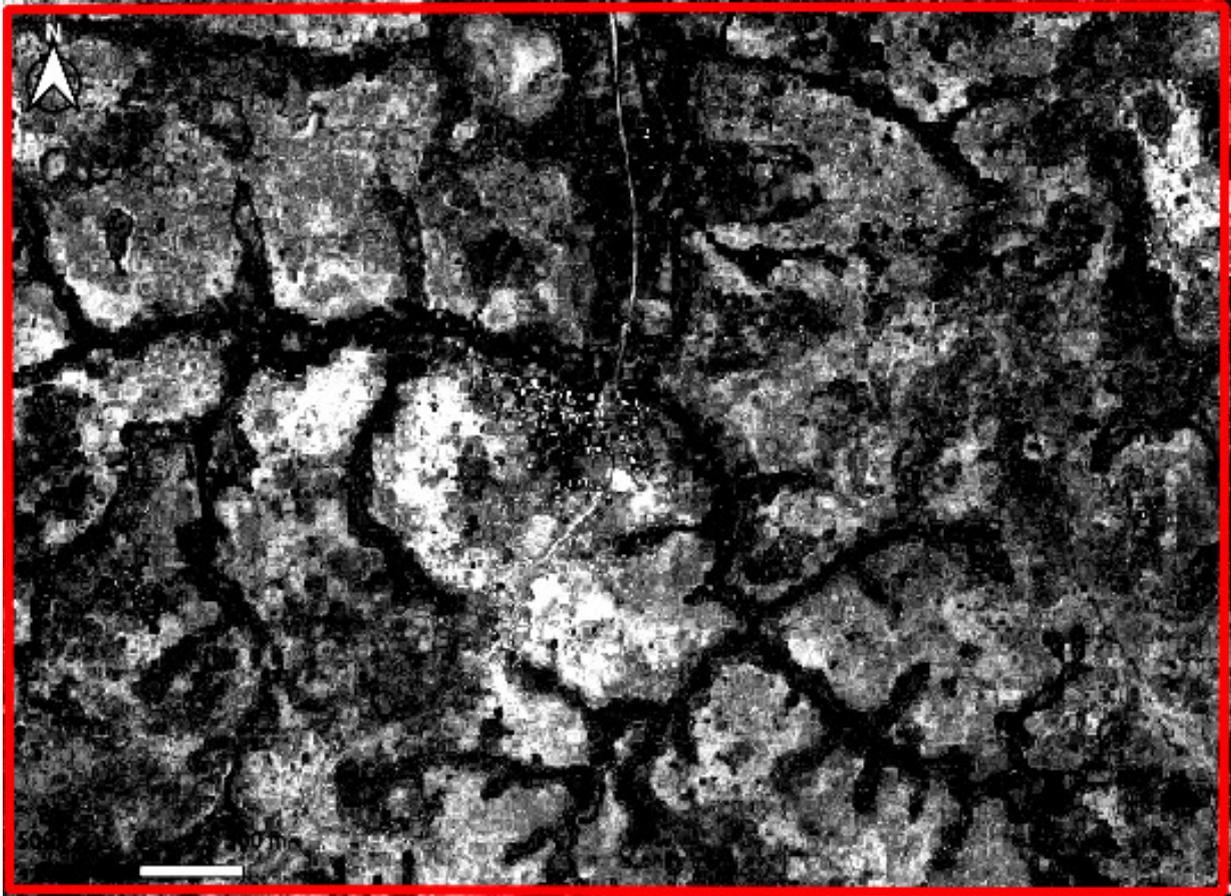


FIG. 5.22 – Extrait de la confiance de la classification supervisée de séries d’images Sentinel-1_L1/-2_L2A avec la légende à 12 classes, de la zone d’intérêt T33PUL.

difficilement toutes les classes alors que la légende à 5 classes discrimine assez bien toutes les classes sur la Figure 5.25D.

5.3.2.4 Comparaison pixel à pixel des classifications supervisées de la zone d’intérêt T32NPL

L’objectif de cette section est d’effectuer la comparaison pixel à pixel entre les classifications des différents mois et de l’année complète 2018, de séries temporelles d’images optiques et radar Sentinel-1_L1/-2_L2A, de la zone d’intérêt T32NPL. Le Tableau 5.9 présente les différentes valeurs de K et FS obtenues au terme de la comparaison pixel à pixel pour les douze mois et l’année complète, avec 9 classes. On observe que les scores de similarité sont faibles dans la comparaison entre les classifications de quelques mois et de l’année complète 2018 et la VT, traduisant ici le fait qu’il y a moins de classifications différentes entre elles. Les résultats de la plupart des classifications se rapprochent : **les taux sont majoritairement élevés. Plus précisément, les valeurs de K et de FS sont plus élevées dans les classifications des mois de janvier, février, mars, juin, juillet et novembre et de l’année complète 2018 par rapport autres classifications mensuelles et annuelle qui possèdent ainsi les meilleurs taux d’accord.** Au contraire, le désaccord entre les classifications des mois d’avril, août et octobre et le reste des classifications demeure ici remarquable avec une légère amélioration dans la classification du mois d’octobre par rapport à celles des mois de septembre, novembre et de l’année complète 2018.

TABLE 5.9 – Coefficients Kappa (K) et F-Scores moyens (FS) obtenus au terme de la comparaison pixel à pixel des classifications mensuelles et annuelle de séries temporelles d’images optiques et radar Sentinel-1_L1/-2_L2A et de la VT avec la légende à 9 classes, de la zone d’intérêt T32NPL.

	jan.		fév.		mar.		avr.		mai		juin		juil.		août.		sep.		oct.		nov.		déc.		2018		VT		
<i>k</i> = 9	K	FS	K	FS	K	FS	K	FS	K	FS	K	FS	K	FS	K	FS	K	FS	K	FS	K	FS	K	FS	K	FS	K	FS	VT
L1-L2A																													
janvier	1,0	100,0	0,7	48,6	0,5	37,3	0,2	18,7	0,4	27,5	0,4	30,4	0,4	30,9	0,1	17,1	0,4	30,0	0,3	24,6	0,6	39,3	0,6	45,2	0,7	48,9	0,5	31,9	
février	0,7	48,6	1,0	100,0	0,5	35,5	0,2	18,3	0,3	26,0	0,4	29,4	0,4	29,1	0,1	16,1	0,4	28,5	0,3	23,4	0,5	36,3	0,6	42,2	0,6	45,8	0,5	29,9	
mars	0,5	37,3	0,5	35,5	1,0	100,0	0,1	17,7	0,3	24,4	0,4	28,4	0,4	28,3	0,1	15,6	0,4	26,3	0,2	22,3	0,4	36,7	0,5	35,0	0,5	38,1	0,4	26,5	
avril	0,2	18,7	0,2	18,3	0,1	17,7	1,0	100,0	0,1	14,8	0,1	17,1	0,1	16,5	0,1	15,6	0,1	15,4	0,1	13,1	0,2	17,2	0,2	18,3	0,2	19,2	0,1	13,4	
mai	0,4	27,5	0,3	26,0	0,3	24,4	0,1	14,8	1,0	100,0	0,3	23,7	0,3	24,1	0,1	14,3	0,3	23,7	0,2	18,7	0,3	26,7	0,3	26,9	0,4	28,2	0,3	22,0	
juin	0,4	30,4	0,4	29,4	0,4	28,4	0,1	17,1	0,2	49,8	1,0	100,0	0,4	29,4	0,1	14,6	0,3	24,4	0,2	20,1	0,4	27,6	0,4	29,4	0,5	32,5	0,4	23,3	
juillet	0,4	30,9	0,4	29,1	0,4	28,3	0,1	16,5	0,3	24,1	0,4	29,4	1,0	100,0	0,1	15,7	0,3	25,0	0,2	21,5	0,4	28,4	0,4	30,4	0,4	36,4	0,4	24,8	
août	0,1	17,1	0,1	16,1	0,1	15,6	0,1	15,6	0,1	14,3	0,1	14,6	0,1	15,7	1,0	100,0	0,1	15,1	0,1	12,7	0,1	16,6	0,1	17,0	0,1	16,3	0,1	14,7	
septembre	0,4	30,0	0,4	28,5	0,4	26,3	0,1	15,4	0,3	23,7	0,3	24,4	0,3	25,0	0,1	15,1	1,0	100,0	0,2	21,3	0,4	29,5	0,4	29,4	0,5	31,8	0,4	24,7	
octobre	0,3	24,6	0,3	23,4	0,2	22,3	0,1	13,1	0,2	18,7	0,2	20,1	0,2	21,5	0,1	12,7	0,2	21,3	1,0	100,0	0,3	25,0	0,3	24,1	0,3	25,9	0,3	21,7	
novembre	0,6	39,3	0,5	36,3	0,4	31,7	0,2	17,2	0,3	26,7	0,4	27,6	0,4	28,4	0,1	16,6	0,4	29,5	0,3	25,0	1,0	100,0	0,6	41,6	0,6	39,4	0,4	29,7	
décembre	0,6	45,2	0,6	42,2	0,5	35,0	0,2	18,3	0,3	26,9	0,4	29,4	0,4	30,4	0,1	17,0	0,4	29,4	0,3	24,0	0,6	41,6	1,0	100,0	0,6	44,7	0,4	30,1	
2018	0,7	48,9	0,7	45,8	0,5	38,1	0,2	19,2	0,4	28,2	0,4	32,5	0,4	36,4	0,1	16,3	0,5	31,8	0,3	25,9	0,6	39,4	0,6	44,7	1,0	100,0	0,5	40,5	
VT	0,5	31,9	0,5	29,9	0,4	26,5	0,1	13,4	0,3	22,0	0,4	23,3	0,4	24,8	0,1	14,7	0,4	24,7	0,3	21,7	0,4	29,7	0,4	30,1	0,5	40,5	1,0	100,0	

k : nombre de classes. VT : vérité terrain.

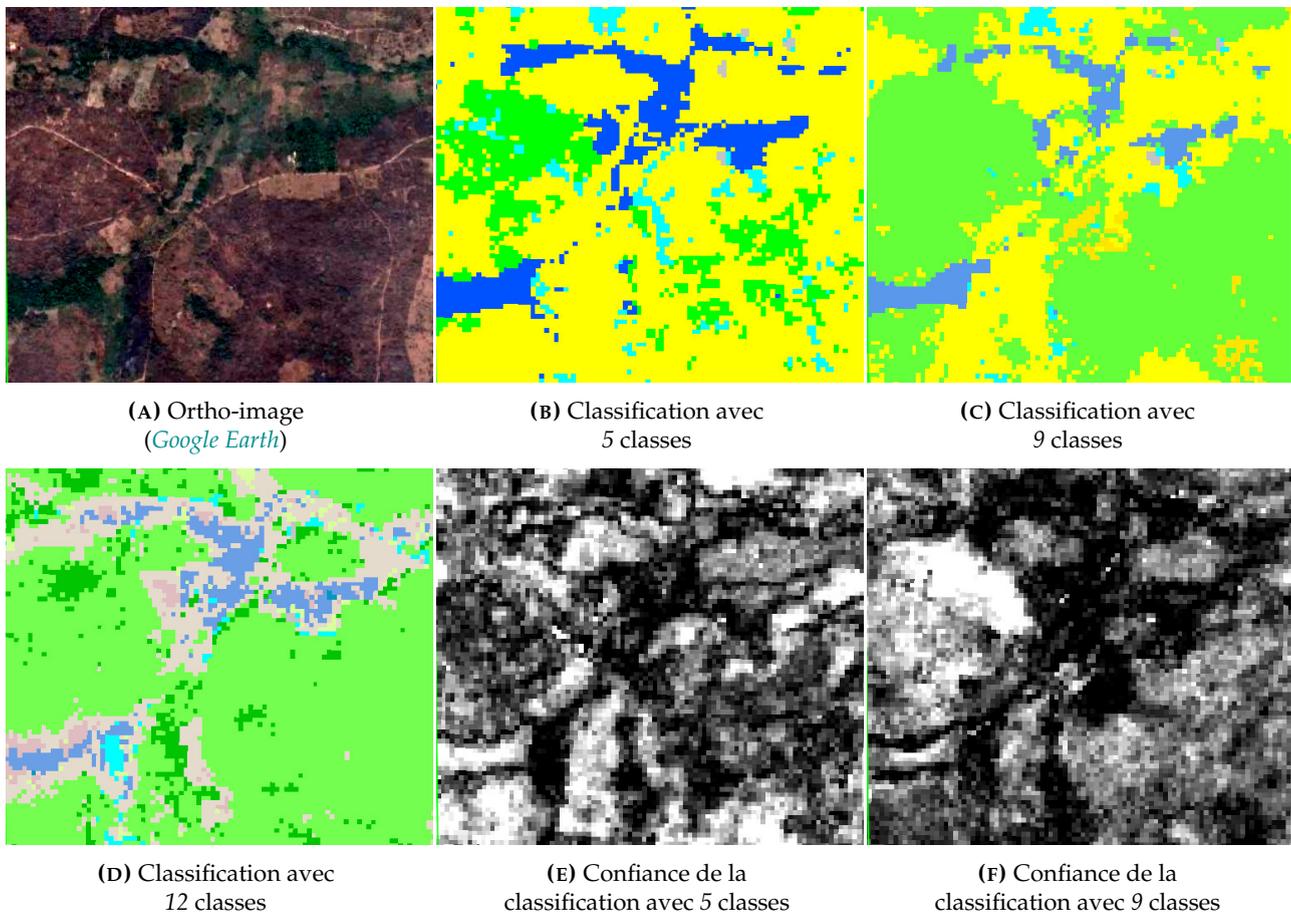


FIG. 5.23 – Extraits de l’ortho-image et des classifications et des confiances de classifications de séries temporelles d’images optiques et radar Sentinel-1_L1/-2_L2A avec les légendes à 5 et 9 et 12 classes, d’une zone rurale sur la zone d’intérêt T32NPL.

5.3.2.5 Comparaison par région des distributions de classes des classifications supervisées de la zone T32NPL

De nouveau, on effectue la moyenne des scores calculés au sein de grandes régions extraites des classifications des différents mois et de l’année complète 2018, de séries temporelles d’images optiques et radar Sentinel-1_L1/-2_L2A et de la VT utilisant la légende à 9 classes. Le Tableau 5.10 présente les moyennes des scores calculés au sein de cellules de taille 200 pixels. On y voit de très faibles valeurs des scores, avec une chute remarquable des scores variant de seulement 0,22 à 0,81 dans la comparaison de la classification du mois de juillet par rapport aux autres classifications et la VT. **La classification du mois d’août demeure très différente avec des scores toujours plus élevées de 0,51 à 0,91. De même, le mois d’avril rejoint août en étant assez différents des autres avec des scores s’étendant de 0,51 à 0,78.** Ceci s’explique ici par les mauvaises qualités des séries d’images optiques des mois d’avril et d’août qui n’ont pu être améliorées en combinaison avec les images radar. Ici, aucune classification ne parvient toujours à se rapprocher de quatre autres classifications à la fois. Par contre, les trois groupes de classifications mensuelles et annuelle (janvier, février et juin); (janvier, février et décembre) et (janvier, février et 2018) se rapprochent des trois classifications des mois de mars; juin et juillet avec de faibles scores de 0,2; 0,24 et 0,28 respectivement.

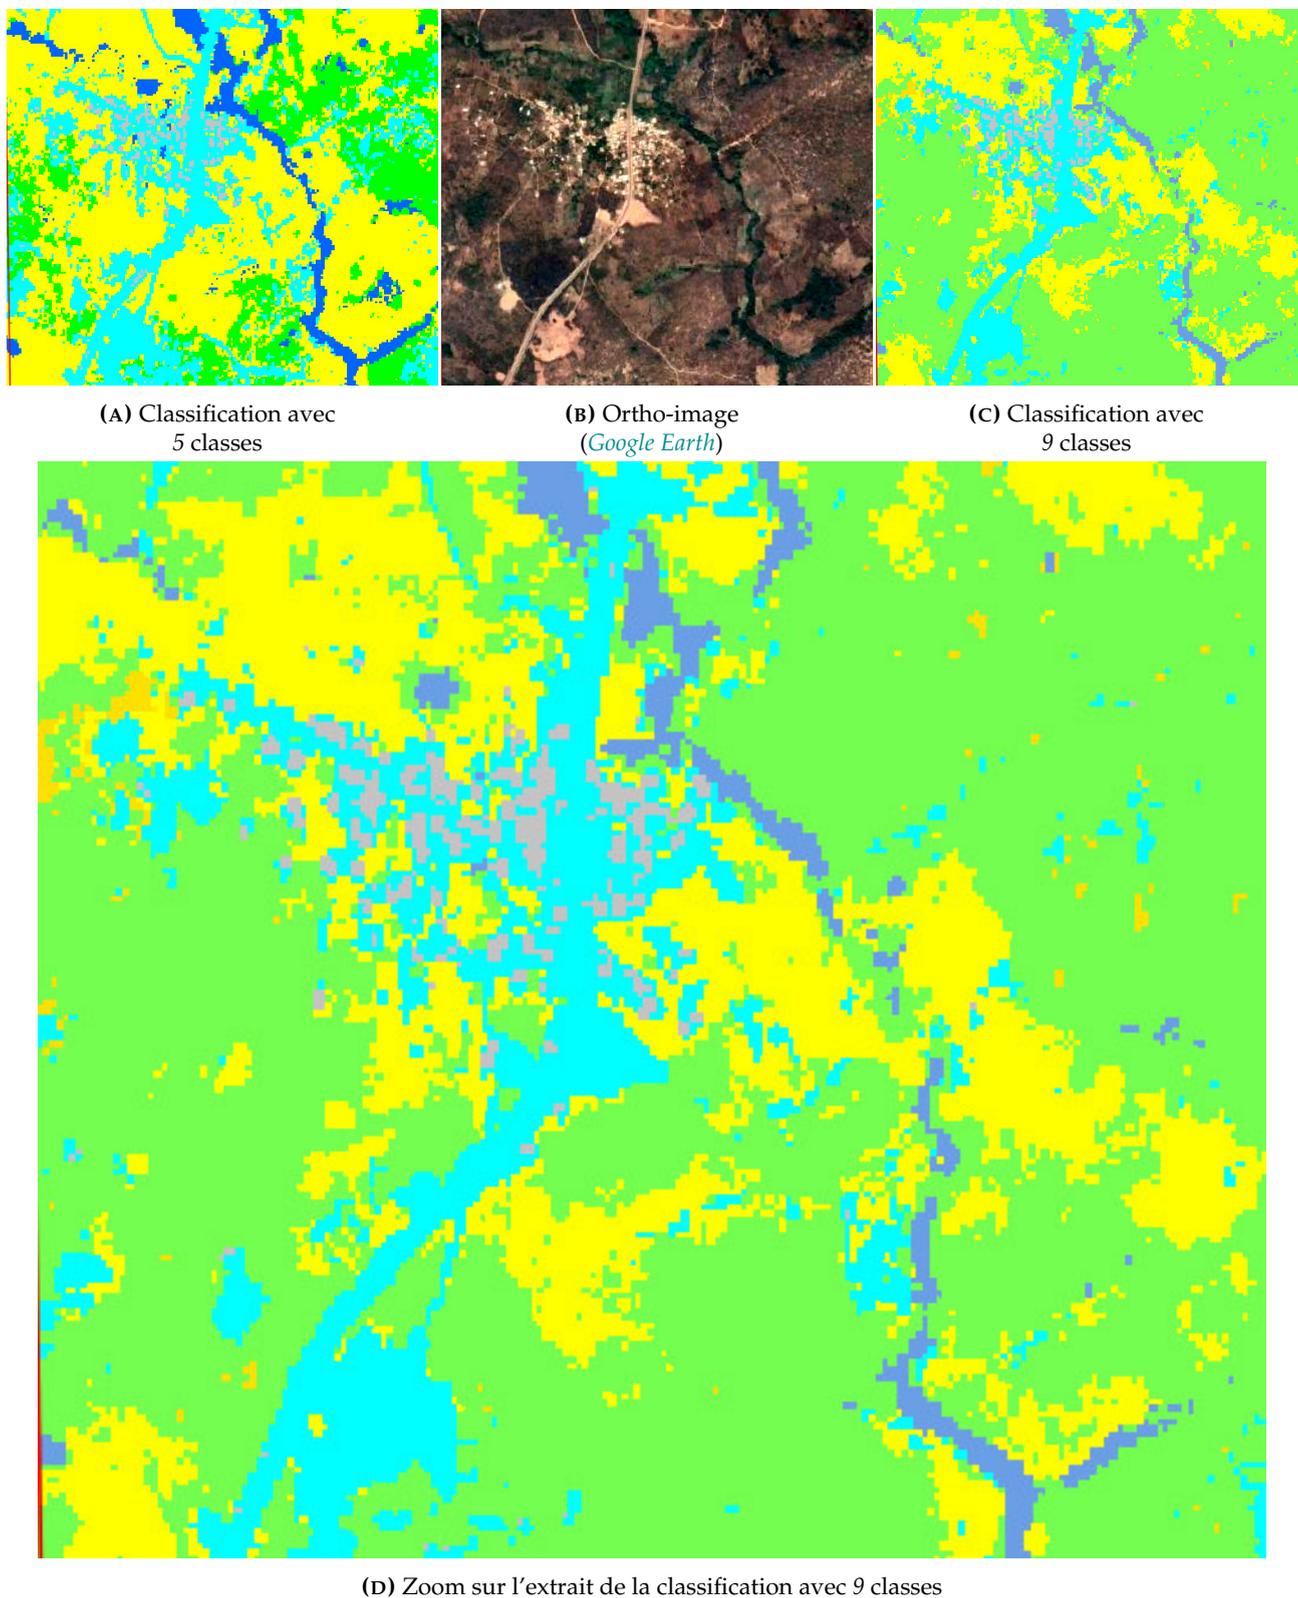


FIG. 5.24 – Extraits de l'ortho-image et des classifications de séries temporelles d'images optiques et radar Sentinel-1_L1/-2_L2A avec les légendes à 5 : ■ : VGT; ■ : AGR; ■ : EAU; ■ : RTE; ■ : BTM et 9 : ■ : FRT; ■ : PRA; ■ : ARB; ■ : AGR; ■ : SFE; ■ : ZHU; ■ : RIV; ■ : RTE; ■ : BTM classes, d'une zone urbaine sur la zone d'intérêt T32NPL.

<i>L1-L2A</i>	jan.	fév.	mar.	avr.	mai	juil.	août.	sept.	oct.	nov.	déc.	2018	VT
janvier	0.00	0.10	0.20	0.70	0.35	0.24	0.28	0.83	0.24	0.37	0.15	0.14	0.30
février	0.10	0.00	0.20	0.70	0.36	0.24	0.28	0.83	0.24	0.36	0.17	0.15	0.30
mars	0.20	0.20	0.00	0.66	0.33	0.20	0.24	0.80	0.22	0.32	0.21	0.21	0.30
avril	0.70	0.70	0.66	0.00	0.64	0.63	0.67	0.51	0.64	0.72	0.69	0.72	0.78
mai	0.35	0.36	0.33	0.64	0.00	0.32	0.36	0.77	0.30	0.43	0.34	0.37	0.46
juin	0.24	0.24	0.20	0.63	0.32	0.00	0.22	0.78	0.21	0.32	0.24	0.26	0.32
juillet	0.28	0.28	0.24	0.67	0.36	0.22	0.00	0.81	0.26	0.31	0.27	0.28	0.32
août	0.83	0.83	0.80	0.51	0.77	0.78	0.81	0.00	0.78	0.87	0.81	0.84	0.91
septembre	0.24	0.24	0.22	0.64	0.30	0.21	0.26	0.78	0.00	0.31	0.23	0.25	0.30
octobre	0.37	0.36	0.32	0.72	0.43	0.32	0.31	0.87	0.31	0.00	0.36	0.38	0.30
novembre	0.16	0.18	0.19	0.67	0.30	0.21	0.25	0.80	0.20	0.34	0.14	0.18	0.31
décembre	0.15	0.17	0.21	0.69	0.34	0.24	0.27	0.81	0.23	0.36	0.00	0.16	0.33
2018	0.14	0.15	0.21	0.72	0.37	0.26	0.28	0.84	0.25	0.38	0.16	0.00	0.30
VT	0.30	0.30	0.30	0.78	0.46	0.32	0.32	0.91	0.30	0.30	0.31	0.30	0.00

TAB. 5.10 – Moyennes des distances entre les histogrammes calculées au sein de cellules de taille 200 pixels extraites des classifications mensuelles et annuelle de séries temporelles d'images optiques et radar Sentinel-1 *L1/-2_L2A* et de la vérité terrain (*VT*) avec la légende à 9 classes, de la zone d'intérêt *T32NPL*.

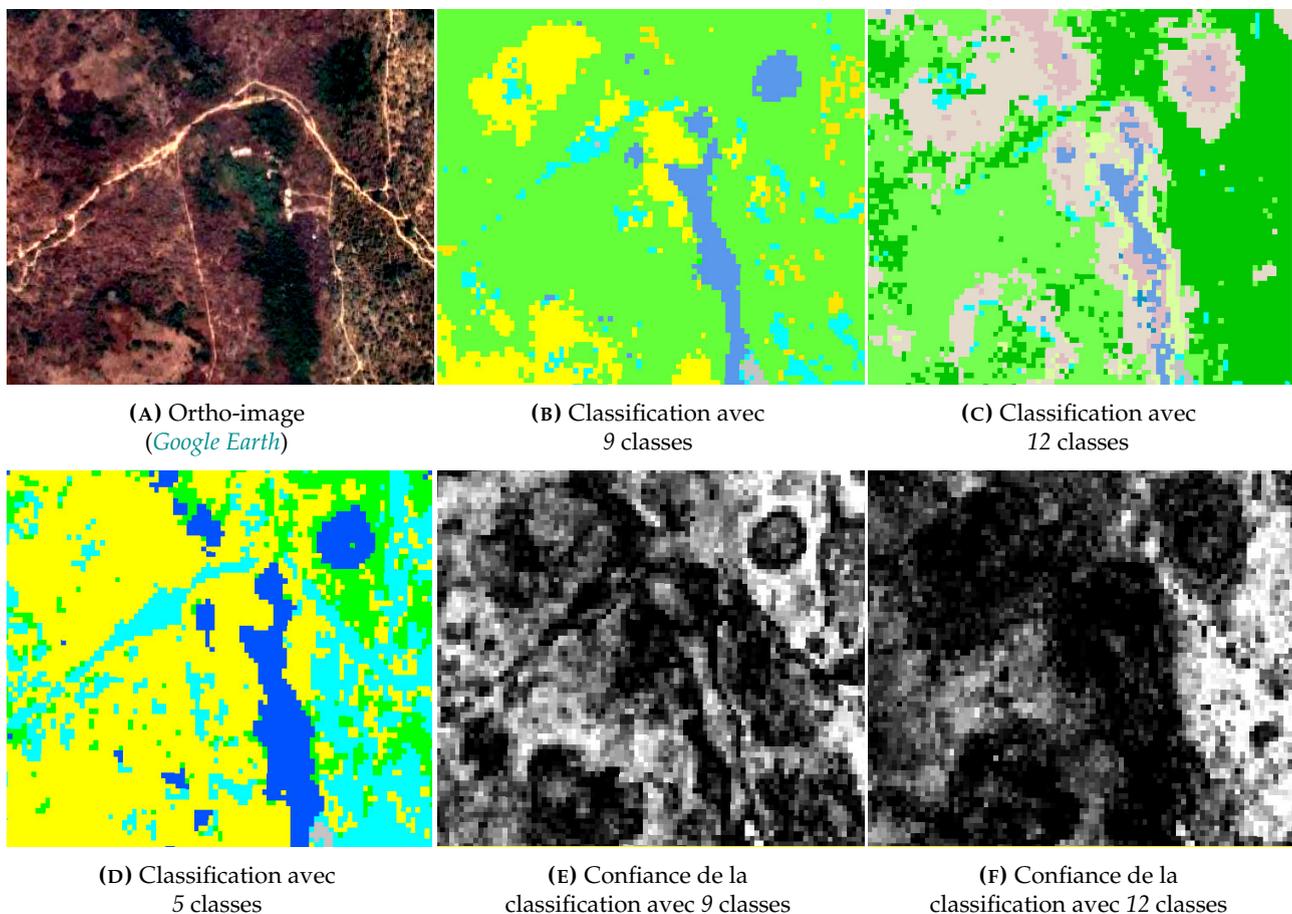


FIG. 5.25 – Extraits de l’ortho-image et des classifications et des confiances de classifications de séries temporelles d’images optiques et radar Sentinel-1_L1/-2_L2A avec les légendes à 5 et 9 et 12 classes, de petites classes locales sur la zone d’intérêt T32NPL.

5.3.2.6 Influence de la nomenclature et de la dimension temporelle des données sur T32NPL

La légende et la période de classification (mensuelles ou annuelle) des données satellitaires sont susceptibles de modifier les performances de classification. Ainsi, l’impact des périodes sur les résultats de classification précédemment étudiés pour les trois légendes (Section 5.3.2.1) est analysé dans cette section.

5.3.2.6.1 Influence de la nomenclature des données de référence sur les classifications supervisées de la zone d’intérêt T32NPL La légende peut modifier les performances de classification. Ainsi, la Section 5.3.2.1 montre qu’on obtient les résultats les plus forts des classifications de l’année complète 2018 pour les trois légendes si l’on considère les FS et les K.

5.3.2.6.2 Influence de la dimension temporelle des données satellitaires sur les classifications supervisées de la zone d’intérêt T32NPL La période de classification des images satellitaires (mensuelles ou annuelle) peut également modifier les performances de classification. Ainsi, la Section 5.3.2.1 montre qu’on obtient les résultats les plus forts pour les trois légendes selon les FS et les K, de la classification de la série annuelle (2018) complète. Bien que les résultats des classifications mensuelles soient moins bons, certaines classifications mensuelles se démarquent à l’instar de celles des mois de mai, septembre et novembre qui se rapprochent de la classification de l’année complète 2018.

5.4 Fusion de classifications en alternative à la classification supervisée

L'objectif de cette partie est d'évaluer qualitativement la fusion tardive des classifications produites avec le jeu de données composés de séries temporelles d'images optiques et radar Sentinel-1_L1/-2_L2A sur les deux zones d'intérêt *T33PUL* et *T32NPL*.

En effet, des problèmes liés notamment aux structures linéaires des classifications de l'année complète 2018 ont été remarqués et approuvés par les différentes analyses statistiques effectuées. De plus, les classifications de certains mois ont été respectivement proches en terme de qualité de la classification annuelle (2018) Ainsi, la fusion des classifications supervisées mensuelles est analysée qualitativement dans cette section pour savoir si elle permet d'améliorer le discernement et la répartition des classes d'OCS. Au total, dix méthodes de fusion ont été distinctement implémentées avec les différentes classifications mensuelles de séries temporelles d'images optiques et radar Sentinel-1_L1/-2_L2A et leurs cartes de probabilité respectives associées pour les trois légendes sur les deux zones d'intérêt *T33PUL* et *T32NPL* :

1. **Fusion bayésienne pondérée par une marge (bayesmarge)** : pour chaque classe, on effectue le produit des cartes de probabilité fournies avec les différentes classifications. Elle est pondérée pour chaque classification par sa marge (différence entre les deux cartes de plus fortes probabilités).
2. **Fusion moyenne pondérée par une marge (moymarge)** (YONG et al., 2004) : pour chaque classe, on effectue une moyenne des cartes de probabilités fournies avec les différentes classifications. Elle est pondérée en fonction de la distribution des probabilités des différentes classes pour chaque classification.
3. **Fusion moyenne simple (moy)** : pour chaque classe, on effectue une simple moyenne des cartes probabilités fournies avec les différentes classifications.
4. **Fusion minimale (min)** : pour chaque classe, on conserve la carte de plus faibles probabilités parmi les différentes classifications.
5. **PCRV2** : on utilise la règle **PCRM0** de redistribution du conflit définie dans (MARTIN et OSSWALD, 2007a) avec une variante *V2* de masse de croyance *MasseV2* développée par (LE-BRIS et al., 2019)
6. **HanV2** : on utilise la règle de redistribution du conflit définie dans (HAN et YANG, 2008) avec la variante *V2* de masse de croyance *MasseV2*.
7. **DSV2** : on utilise la règle de **Dempster-Shafer (DS)** avec la variante *V2* de masse de croyance *MasseV2*.
8. **RF** : on fusionne les classifications en faisant apprendre à nouveau le classifieur **RF**.
9. **SVM-lin_t0** : on fusionne les classifications en faisant apprendre un classifieur **SVM** linéaire, **SVM-linéaire**.
10. **SVM-rbf_t2** : on fusionne les classifications en faisant apprendre un classifieur **SVM** à noyau gaussien K_{rbf} – *radial basis function (rbf)* (SCHÖLKOPF et SMOLA, 2002), **SVM-rbf**.

5.4.1 Zone d'intérêt T33PUL (ZONE1, Nord)

5.4.1.1 Évaluation qualitative sur la zone T33PUL

Les métriques quantitatives sur une très grande surface ne sont toujours pas en mesure de révéler plusieurs types d'erreurs présentes dans les cartes d'OCS malgré l'utilisation ici de la combinaison d'images optiques et radar. C'est ainsi qu'une inspection visuelle est nécessaire afin d'identifier différents problèmes qui sont également analysés dans cette section.

5.4.1.1.1 Paysages difficiles dans les classifications supervisées de la zone d'intérêt T33PUL Afin de mettre en évidence l'avantage des méthodes de fusion de classification supervisée sur des zones fragmentées ou les régions à topographie irrégulière, une étude qualitative comparative visuelle de la classification de l'année complète 2018 et de la fusion des classifications mensuelles est nécessaire. Cette étude vise à déterminer si changer de méthode de fusion tardive de classifications mensuelles améliore la qualité des cartes d'OCS produites. Ainsi, les résultats de la classification annuelle et des fusions de classifications mensuelles sont étudiés en détail dans cette section sur deux types de zones : **une zone rurale (Figure 5.26) et une zone urbaine (Figure 5.27).**

La classification de l'année complète 2018 avec 5 classes de la zone rurale de la Figure 5.26A est identique à celle de la Figure 5.11B. Les dix fusions sont représentées sur les Figures 5.26C-L. On peut remarquer quelques confusions entre les classes VGT et RTE dans les fusions des méthodes **bayesmarge ; moymarge ; moy ; PCRV2 ; HanV2 et DSV2** sur les Figures 5.26C-E et 5.26G-I. **Toutes les classes parviennent à être détectées dans les fusions des méthodes par entraînement des classifieurs RF et SVM : RF ; SVM-lin_t0 et SVM-rbf_t2** dans lesquelles les confusions entre les classes VGT et RTE sont très réduites sur les Figures 5.26J-L. Bien que la classe EAU contient quelques zones d'ombres, toutes les classes sont assez bien représentées dans les fusions des deux méthodes par **RF et SVM-lin_t0** qui sont par ailleurs meilleures que la classification de la combinaison d'images optiques et radar de l'année complète 2018 pour la légende à 5 classes.

Les méthodes de fusion par **RF, SVM-lin_t0 et SVM-rbf_t2** des Figures 5.27A-C sont effectuées avec 12 classes sur la zone urbaine (Figure 5.12B). Pour la méthode par **SVM-lin_t0**, la fusion des classes FOU ; RTE et BTM (Figure 5.27A) donne les meilleurs résultats, avec quelques confusions entre ces classes. Les classes ZHU et RIV sont plutôt détectées en trace pour la méthode par **RF** contrairement aux deux méthodes par **SVM-lin_t0 et SVM-rbf_t2** qui ressortent mieux ces deux classes d'eau (Figures 5.27B(D) et 5.27C). En particulier, ces deux dernières méthodes ont permis de représenter distinctement les cinq précédentes classes. Plus précisément, la fusion de classifications des classes ZHU et RIV donne de meilleurs résultats pour la méthode par **SVM-lin_t0** (Figure 5.27B(D)). **Cette difficulté de détection, que l'on avait déjà observée sur la zone rurale, pourrait être améliorée également en utilisant les synthèses mensuelles.**

5.4.1.1.2 Petites classes locales dans les classifications supervisées de la zone d'intérêt T33PUL Pour la légende à 5 classes, les classes EAU ; RTE et BTM sont minoritaires. Ces classes sont également concentrées dans des régions spécifiques de la zone d'intérêt T33PUL. La Figure 5.28 illustre comment les fusions des méthodes **bayesmarge ; moymarge ; moy ; min ; PCRV2 ; HanV2 et DSV2** ressortent assez bien les classes tout en confondant la plupart sur les Figures 5.28C-F et 5.28G-I. Par ailleurs, **les fusions des trois méthodes par RF ; SVM-lin_t0 et SVM-rbf_t2 (Figures 5.28J-L) donnent de bons résultats qui sont meilleurs pour la méthode par SVM-lin_t0 qui ressort toutes les classes en réduisant les confusions entre ces dernières sur la Figure 5.28K.**

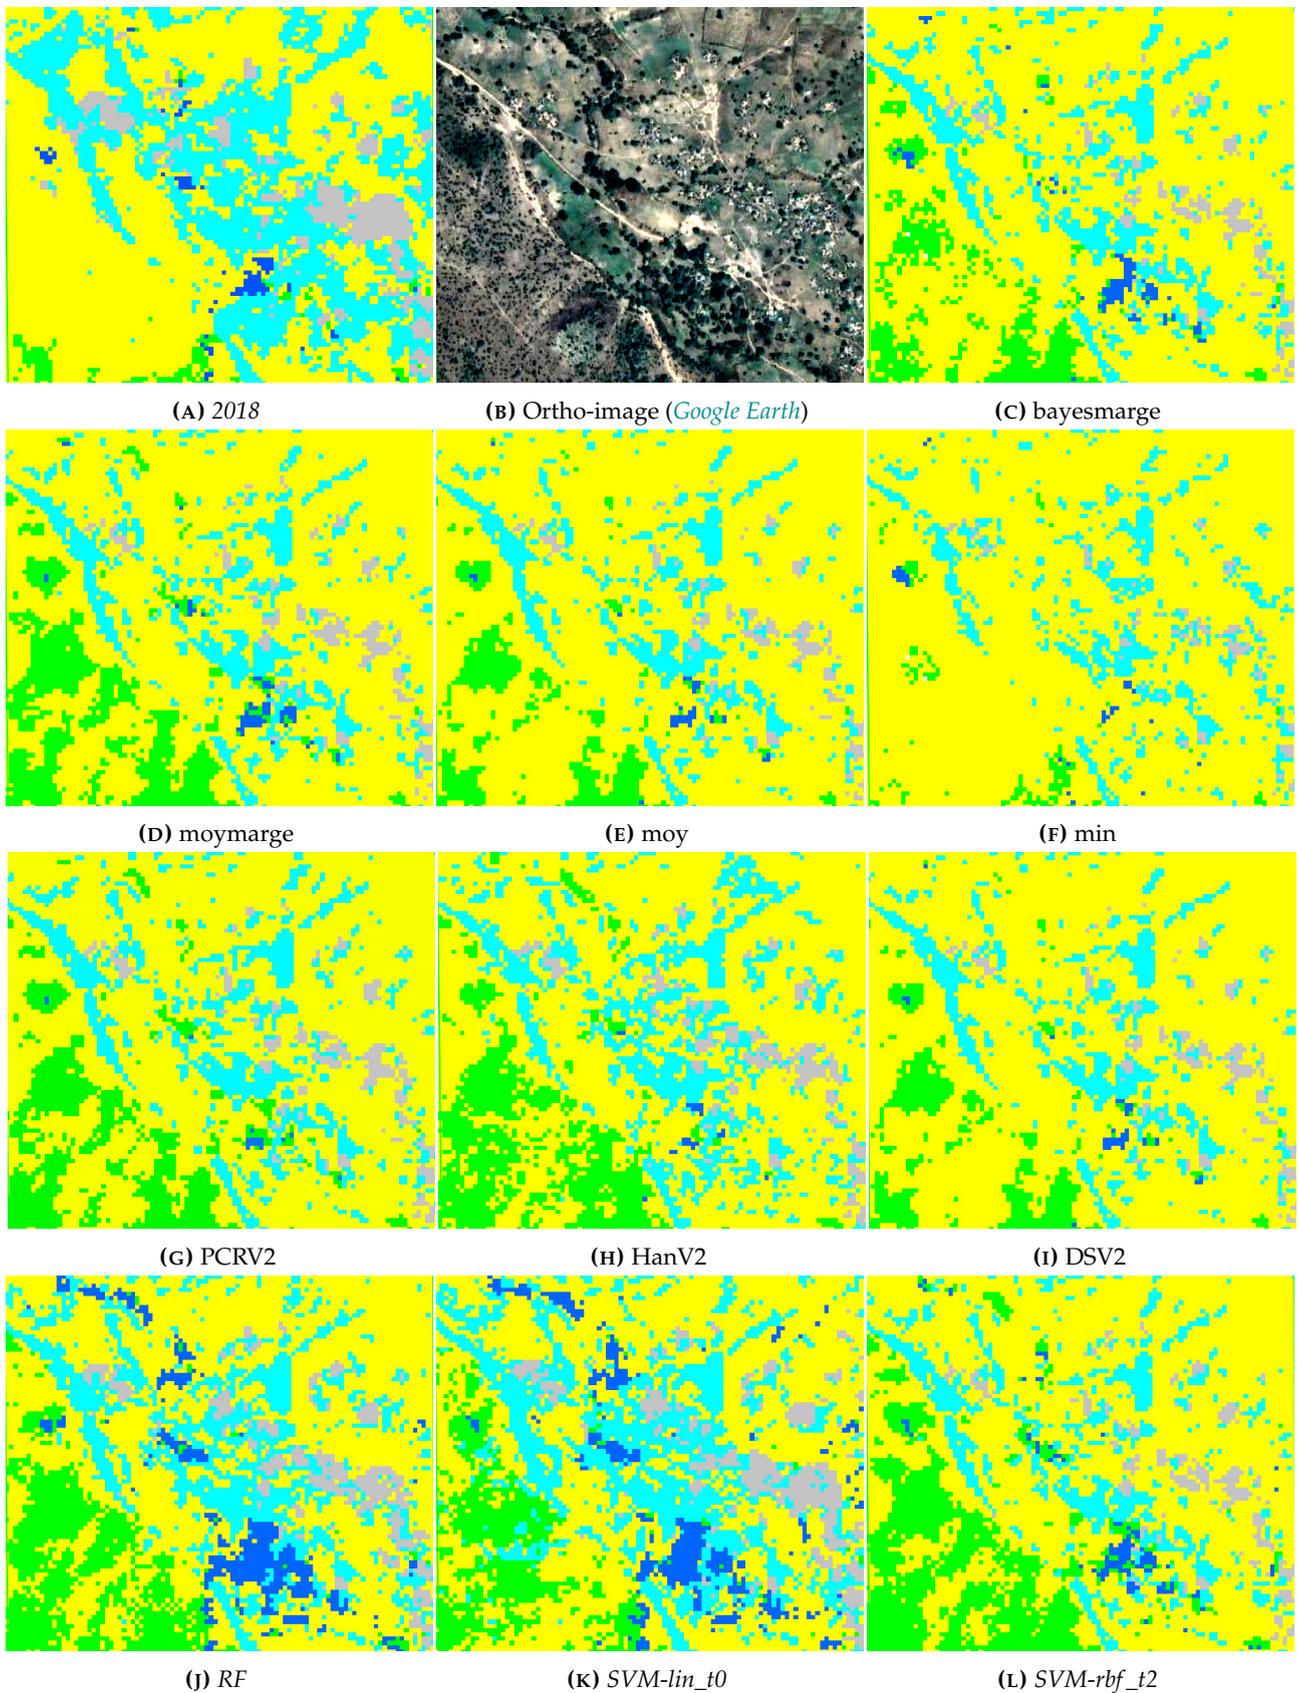


FIG. 5.26 – Extraits de la classification supervisée de la série annuelle d’images optiques et radar Sentinel-1_L1/-2_L2A, de l’ortho-image et des dix fusions de classifications mensuelles avec la légende à 5 classes : ■ : VGT; ■ : AGR; ■ : EAU; ■ : RTE; ■ : BTM, d’une zone rurale sur la zone d’intérêt T33PUL.

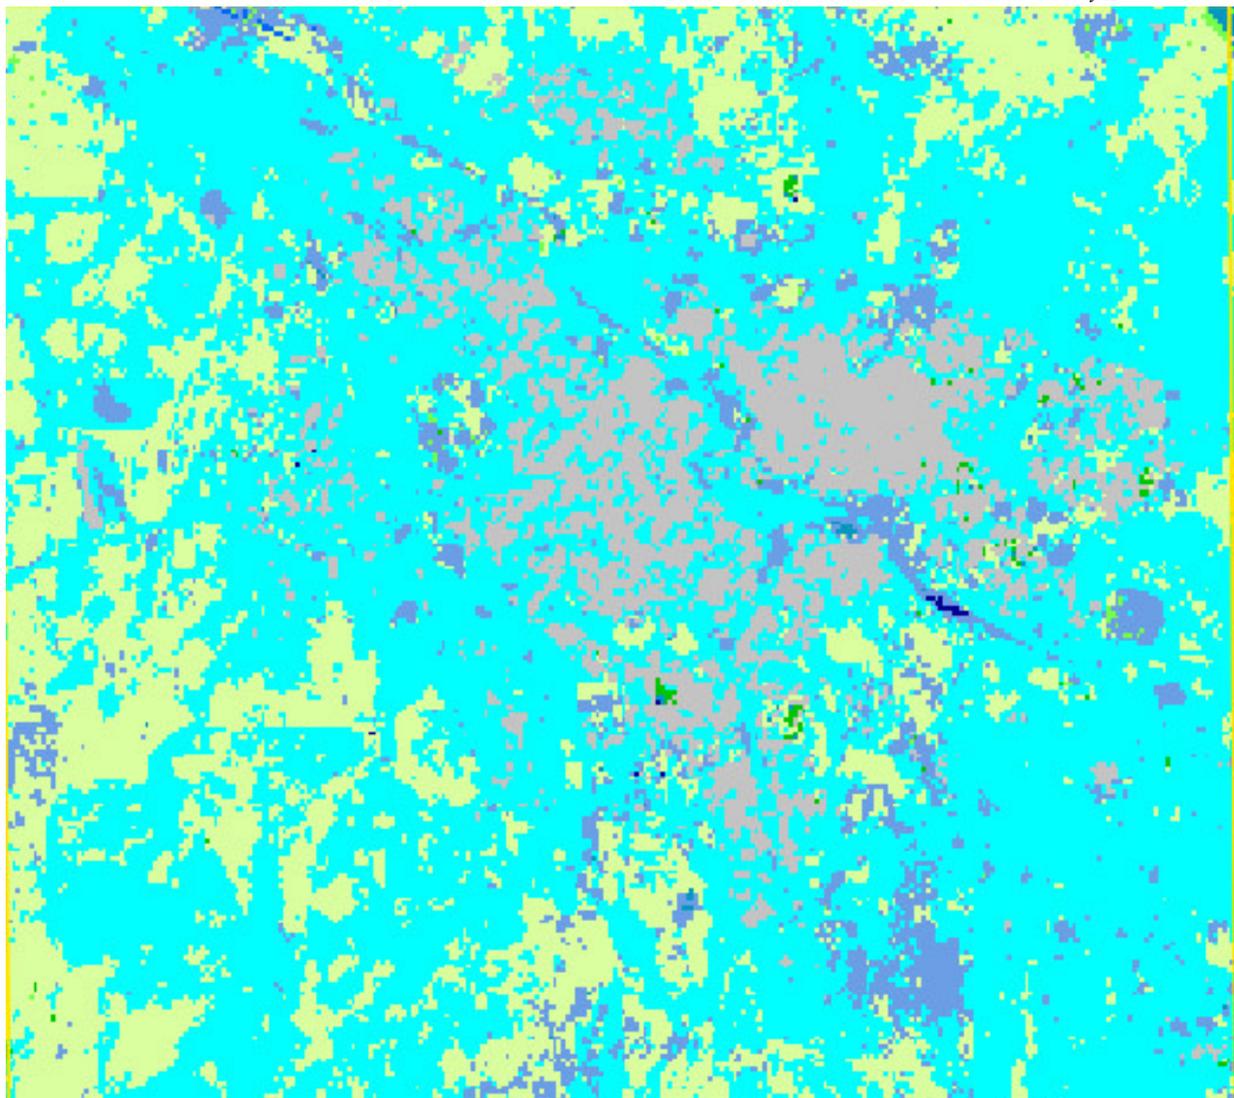
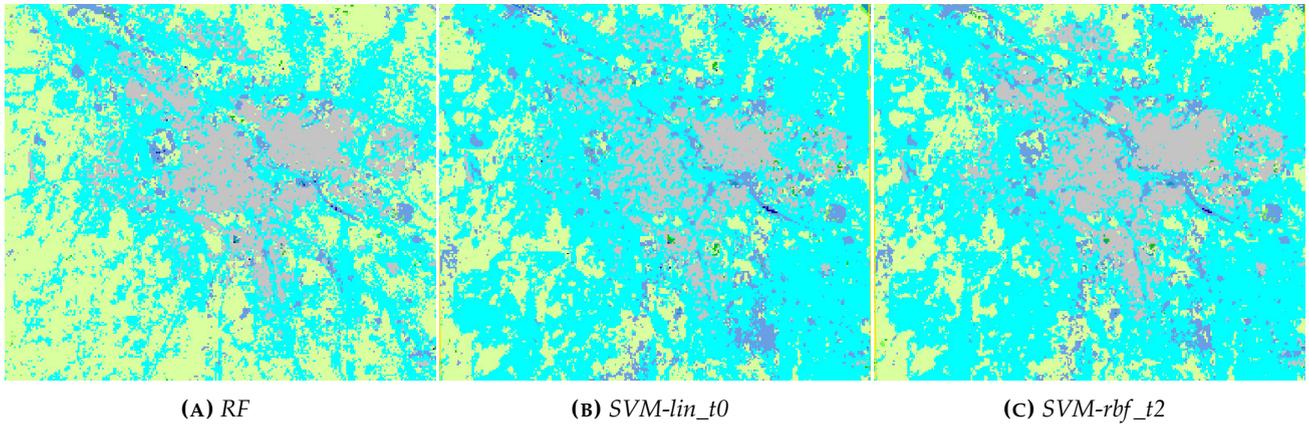


FIG. 5.27 – Extraits des trois fusions RF et SVM-*lin_t0* et SVM-*rbf_t2* de classifications mensuelles de séries temporelles d'images optiques et radar Sentinel-1_L1/-2_L2A avec la légende à 12 classes : ■ : VNC; ■ : VHB; ■ : FOU; ■ : FFE; ■ : TCU; ■ : ARB; ■ : ZHH; ■ : SFE; ■ : ZHU; ■ : RIV; ■ : RTE; ■ : BTM d'une zone urbaine sur la zone d'intérêt T33PUL.

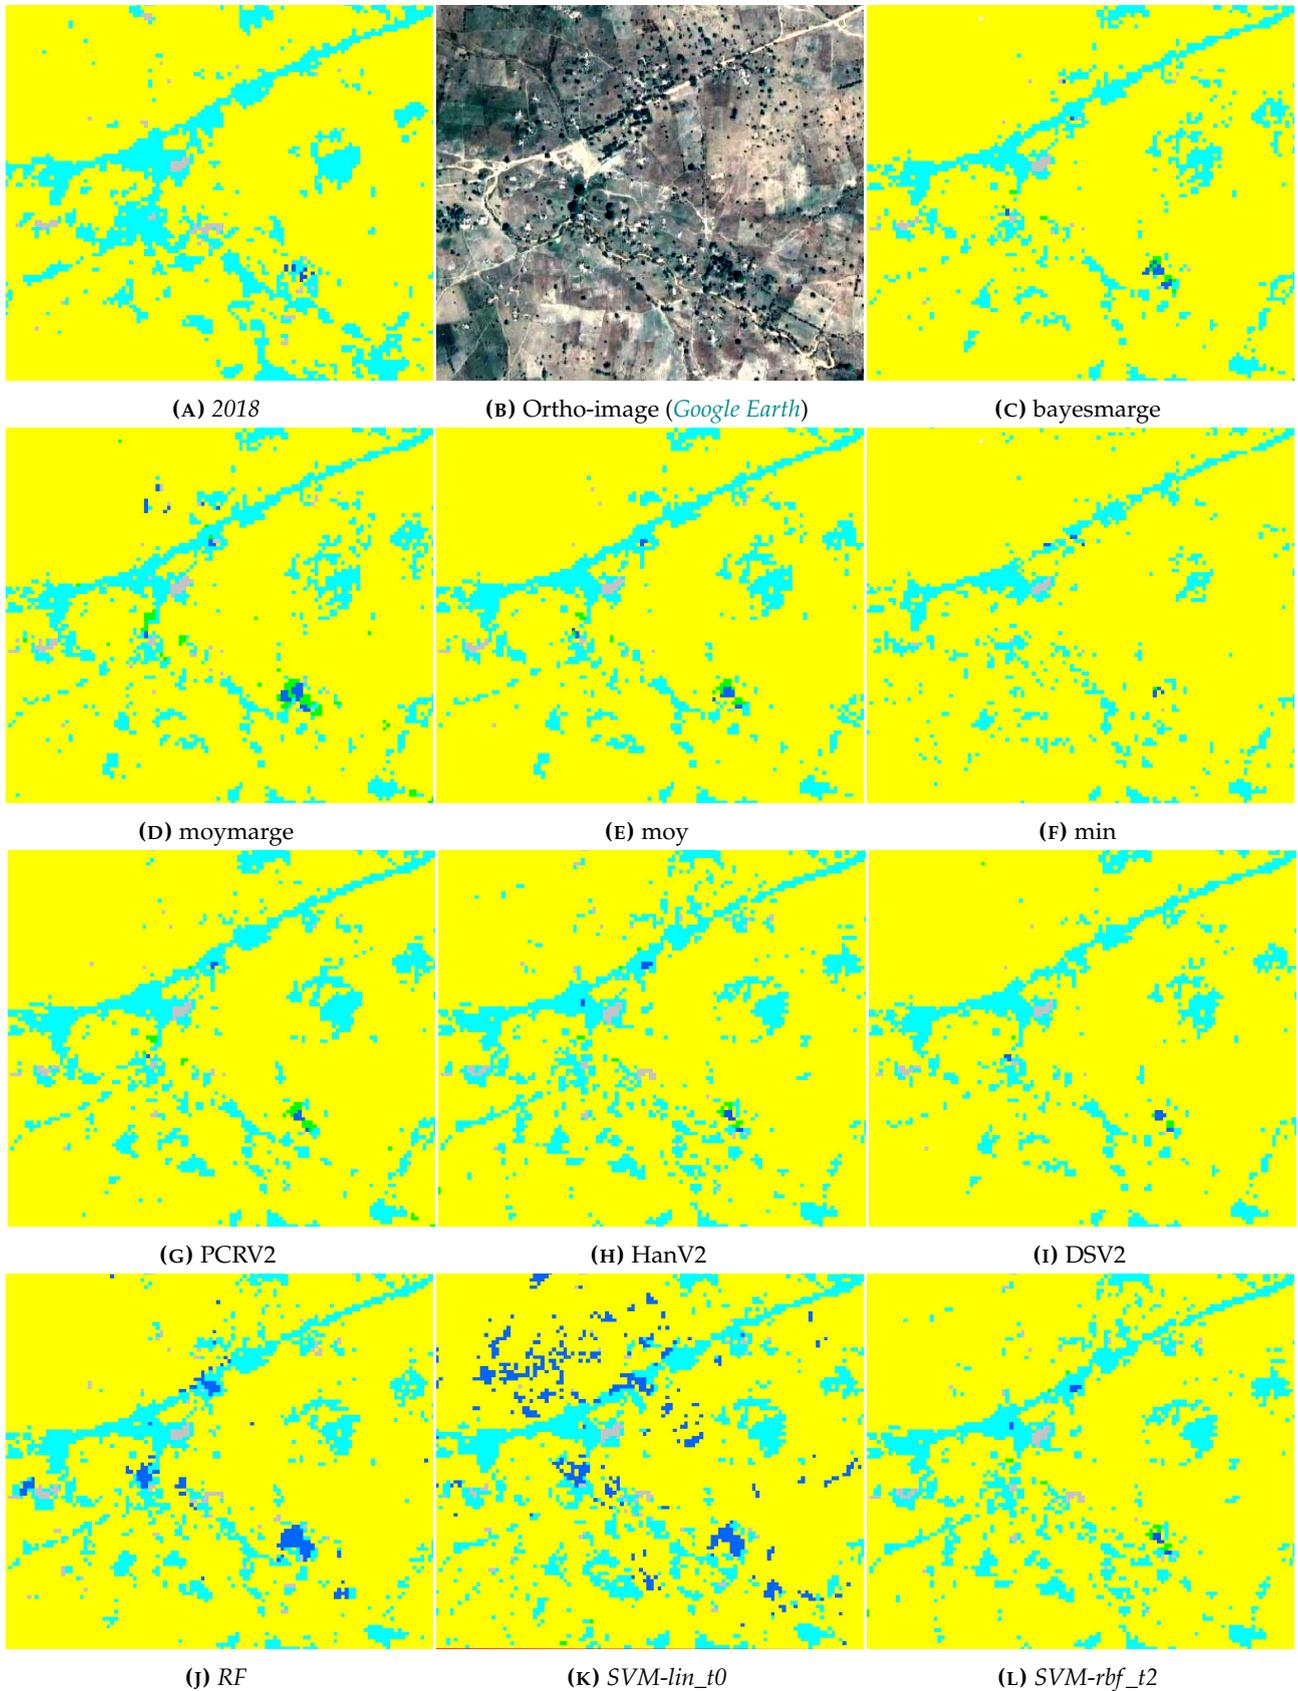


FIG. 5.28 – Extraits de la classification supervisée de la série annuelle d'images optiques et radar Sentinel-1_L1/-2_L2A, de l'ortho-image et des dix fusions de classifications mensuelles avec la légende à 5 classes : ■ : VGT; ■ : AGR; ■ : EAU; ■ : RTE; ■ : BTM, de petites classes locales sur la zone d'intérêt T33PULL.

5.4.2 Zone d'intérêt T32NPL (ZONE2, Ouest-Centre)

5.4.2.1 Evaluation qualitative des classifications supervisées de la zone d'intérêt T32NPL

De manière similaire à la zone d'intérêt T33PUL, une évaluation visuelle permet d'analyser différents problèmes identifiés sur la zone d'intérêt T32NPL.

5.4.2.1.1 Paysages difficiles dans les classifications supervisées de la zone d'intérêt T32NPL

L'étude qualitative comparative visuelle de la classification annuelle et des fusions de classifications mensuelles pour les légendes à 5 et 9 classes est également détaillée dans cette section, sur deux types de zones : **une zone rurale (Figure 5.29) et une zone urbaine (Figure 5.30).**

La classification de séries temporelles de l'année complète 2018 avec 5 classes de la zone rurale de la Figure 5.29A est identique à celle de la Figure 5.23B. Les dix fusions de classifications pour la légende à 5 classes sont représentées sur les Figures 5.29C-L. On peut remarquer un peu de confusion entre les classes VGT et EAU dans les fusions des méthodes **bayesmarge**; **moymarge**; **min**; **PCRv2** et **HanV2** sur les Figures 5.29C, 5.29D, 5.29E, 5.29G et 5.29H. **Toutes les classes parviennent à ressortir clairement et précisément sans poser de problèmes dans les fusions des méthodes par entraînement des classifieurs RF et SVM : RF; SVM-lin_t0 et SVM-rbf_t2** dans lesquelles les confusions entre les classes VGT et EAU sont suffisamment réduites sur les Figures 5.29J-L. Bien que la classe RTE soit toujours faiblement représentée, toutes les classes sont suffisamment et précisément représentées dans les fusions des deux méthodes par **SVM-lin_t0** et **SVM-rbf_t2** qui sont par ailleurs meilleures que la classification de la combinaison d'images optiques et radar de l'année complète 2018 avec 5 classes.

Les méthodes de fusion par **RF; SVM-lin_t0** et **SVM-rbf_t2** des Figures 5.30A-B(D) sont effectuées pour la légende à 9 classes sur la zone urbaine de la Figure 5.24B. Avec la méthode par **RF**, la fusion de classifications des classes AGR; RTE et BTM (Figure 5.30A) donne les meilleurs résultats en présentant quelques confusions entre ces classes du fait de la présence d'échantillons mal étiquetés dans les données d'apprentissage qui affectent la qualité de la classification. Les classes ZHU et RIV sont plutôt détectées en trace avec la méthode par **RF** contrairement aux deux méthodes par **SVM-lin_t0** et **SVM-rbf_t2** qui représentent mieux ces deux classes d'eau (Figures 5.30B(D)-C). En particulier, ces deux dernières méthodes ont permis de bien discriminer les cinq précédentes classes. Plus précisément, la fusion de classifications des classes ZHU et RIV donne de meilleurs résultats avec la méthode par **SVM-lin_t0** (Figure 5.30B(D)), même si la classe ZHU demeure très peu détectée dans la fusion par cette méthode. **Cette difficulté de détection, que l'on avait auparavant observée sur la zone rurale, pourrait être améliorée en utilisant les synthèses mensuelles de séries temporelles de la combinaison d'images optiques et radar Sentinel-1_L1/-2_L3A.**

5.4.2.1.2 Petites classes locales sur la zone T32NPL

Ici, les classes EAU; RTE et BTM sont toujours minoritaires pour la légende à 5 classes. Ces classes sont également concentrées dans des régions spécifiques de la zone d'intérêt T32NPL. La Figure 5.31 illustre ici comment les fusions des méthodes **bayesmarge**; **moymarge**; **moy**; **min**; **PCRv2**; **HanV2** et **DSV2** ressortent assez bien les classes avec des confusions réduites sur les Figures 5.31C-I. Par ailleurs, **les fusions des trois méthodes par RF; SVM-lin_t0 et SVM-rbf_t2 (Figures 5.31J-L) donnent également de bons résultats qui sont meilleurs avec la méthode par SVM-rbf_t2 qui ressort toutes les classes avec quelques confusions entre les classes VGT et EAU sur la Figure 5.31L.**

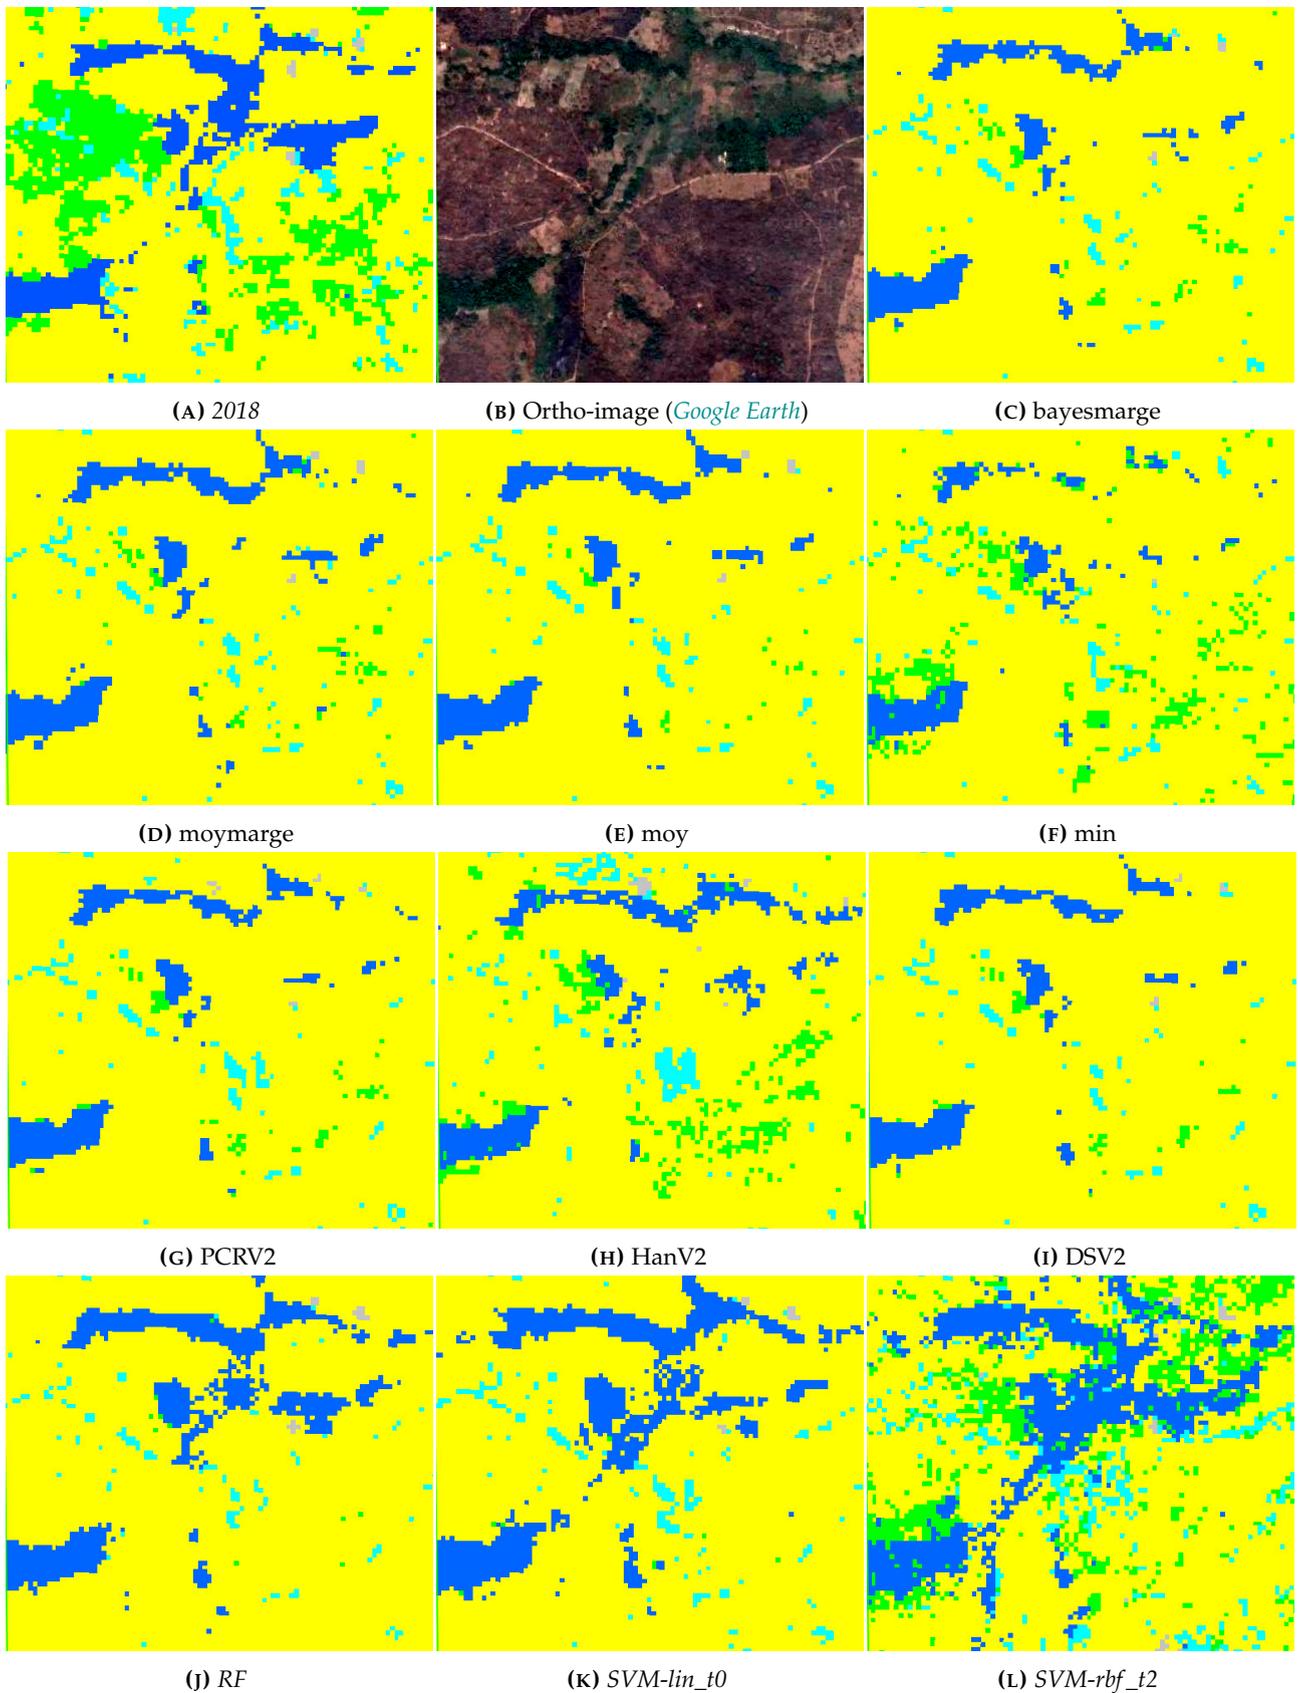


FIG. 5.29 – Extraits de la classification annuelle, de l'ortho-image et des dix fusions de classifications mensuelles de séries temporelles d'images optiques et radar Sentinel-1_L1/-2_L2A avec la légende à 5 classes : ■ : VGT; ■ : AGR; ■ : EAU; ■ : RTE; ■ : BTM, d'une zone rurale sur la zone d'intérêt T32NPL.

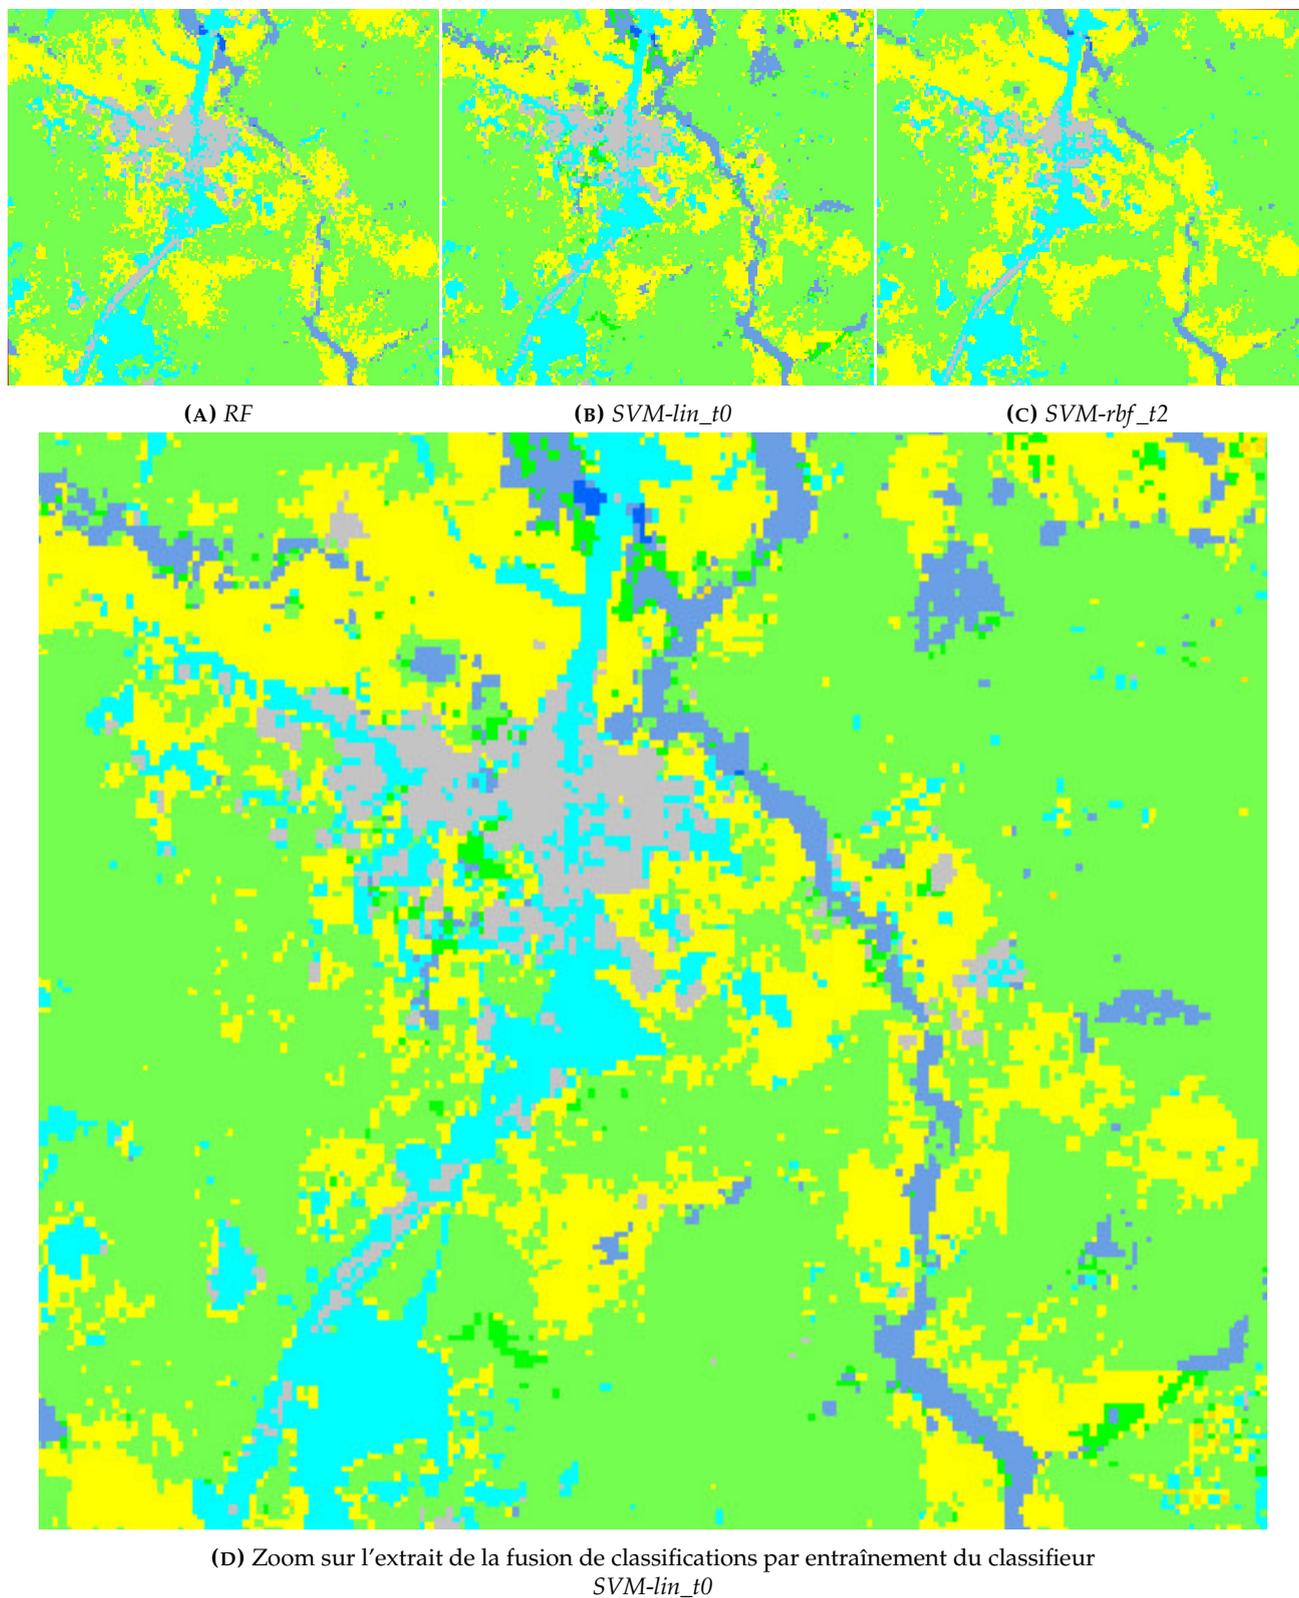


FIG. 5.30 – Extraits des trois fusions *RF* et *SVM-lin_t0* et *SVM-rbf_t2* de classifications mensuelles de séries temporelles d'images optiques et radar Sentinel-1_L1/-2_L2A avec la légende à 9 classes : ■ : FRT; ■ : PRA; ■ : ARB; ■ : AGR; ■ : SFE; ■ : ZHU; ■ : RIV; ■ : RTE; ■ : BTM d'une zone urbaine sur la zone d'intérêt T32NPL.

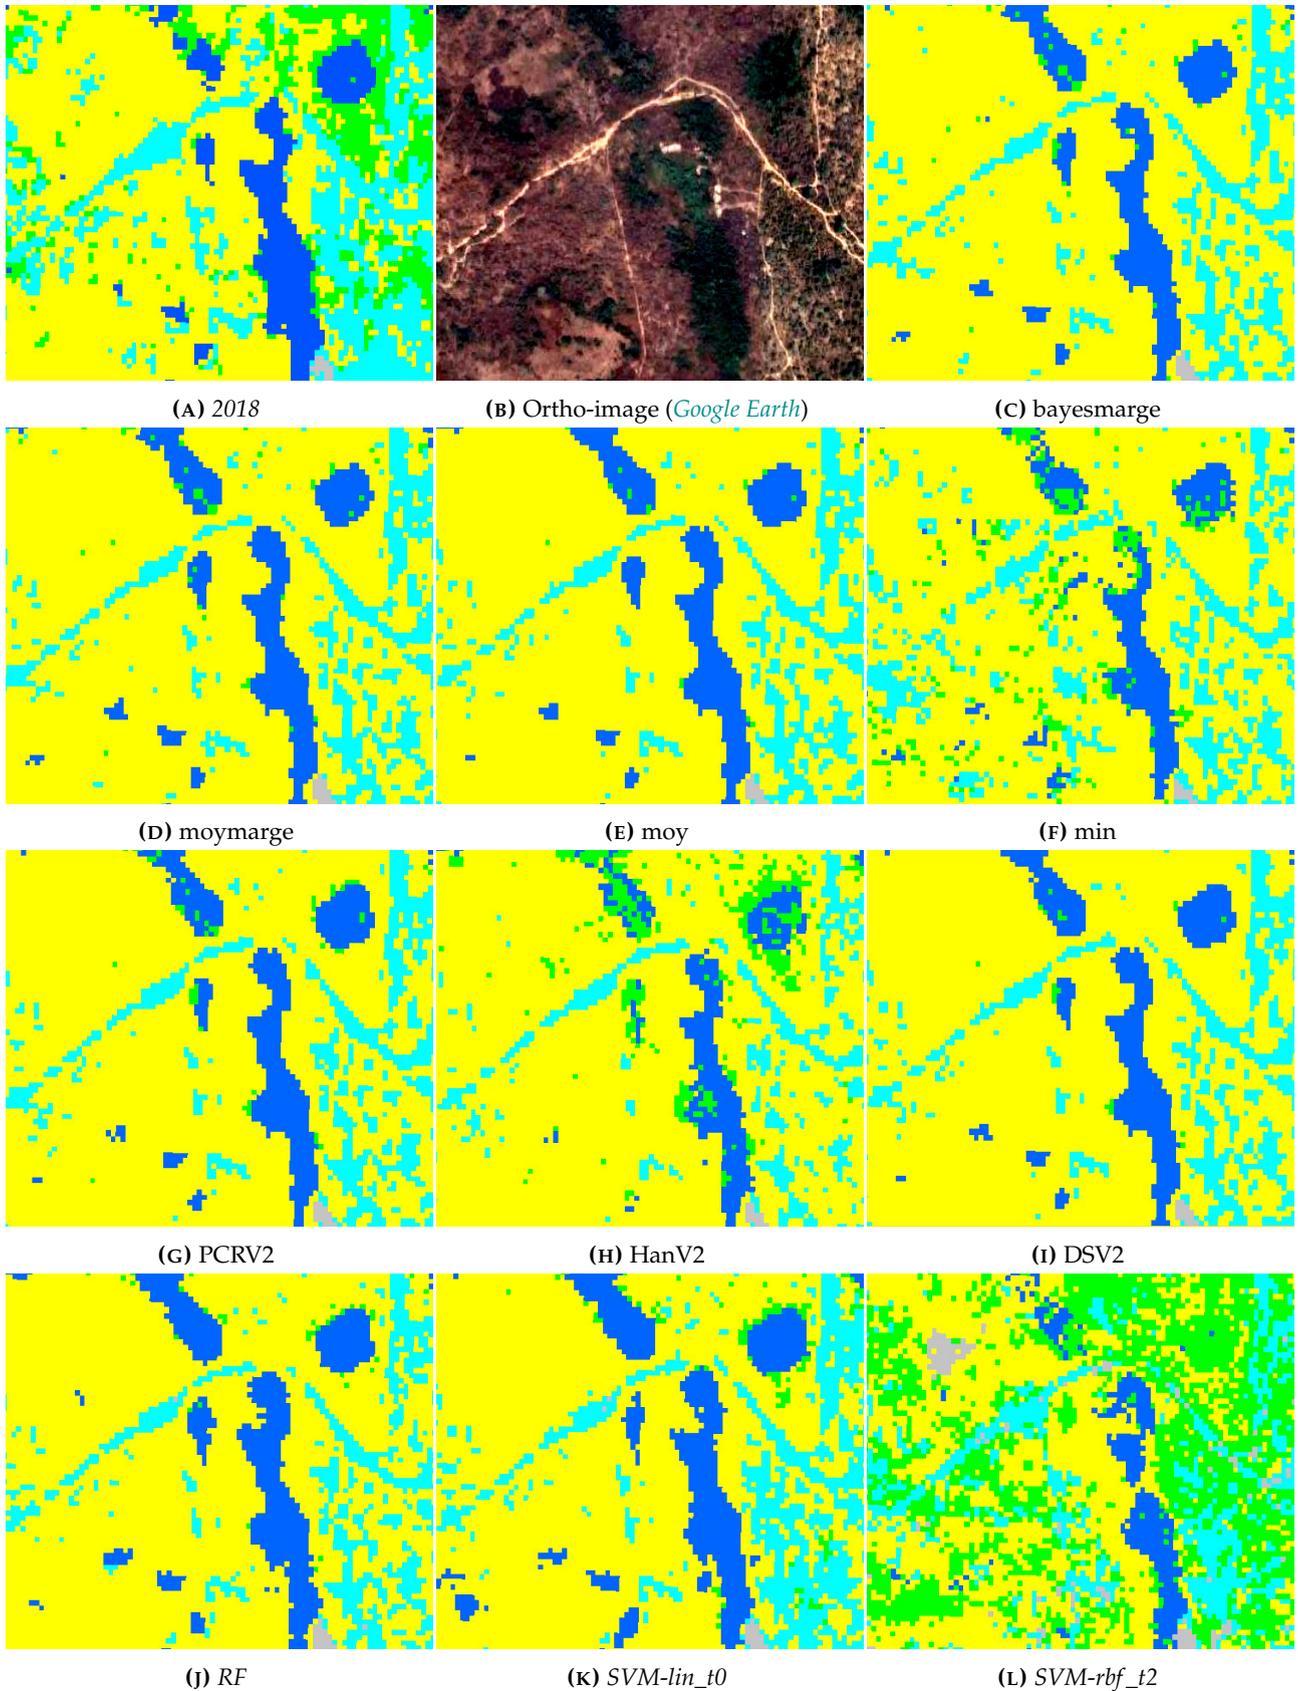


FIG. 5.31 – Extraits de la classification annuelle, de l'ortho-image et des dix fusions de classifications mensuelles de séries temporelles d'images optiques et radar Sentinel-1_L1/-2_L2A avec la légende à 5 classes : ■ : VGT; ■ : AGR; ■ : EAU; ■ : RTE; ■ : BTM, de petites classes locales sur la zone d'intérêt T32NPL.

5.5 Conclusion

Dans ce chapitre, un cadre méthodologique visant à prendre en compte les données radar du satellite Sentinel-1 dans la cartographie de l'OCS a été étudié. La solution proposée ici consiste à ajouter des séries temporelles d'images radar Sentinel-1 au processus de classification suivi d'une étape de fusion afin de détecter davantage les classes d'OCS. L'objectif principal est alors d'améliorer les performances de classification ainsi que la qualité des cartes d'OCS produites.

La fusion tardive de décisions étudiée ici repose sur deux approches principales : 1) l'approche pour les niveaux de fusion d'échelle spatiale et de processus d'interpolation temporelle conséquente, et 2) l'approche pour les primitives qui utilise des techniques supervisées telles que les forêts aléatoires *RF* et les machines à vecteurs de support *SVM*. Après avoir réalisé un état de l'art sur la fusion de données en télédétection, deux catégories de fusion tardive de classifications au niveau de la décision ont été étudiées. Au total, dix méthodes distinctes de fusion tardive de classifications ont été mises en oeuvre et analysées qualitativement.

Les classifications de l'OCS ont été effectuées sur les zones d'intérêt *T33PUL* et *T32NPL* avant d'être évaluées quantitativement pour un jeu de données contenant des séries temporelles d'images radar Sentinel-1 dans le cadre d'étude de l'apport de l'imagerie Sentinel-1 par rapport à l'imagerie Sentinel-2 seule lors de l'auto-entraînement (*APP1*) au cours de la stratégie d'expérimentations de classifications (*STR12*) sur une tuile Sentinel-2 et de la fusion des résultats de classifications comme une alternative à la classification supervisée directe.

L'étude de la première stratégie (*STR1*) montre que les résultats sont meilleurs pour un nombre d'échantillons d'apprentissage suffisant par classe et un paramétrage optimal dans les classifications des mois de février pour la légende à 9 classes et novembre pour la légende à 12 classes uniquement sur la zone d'intérêt *T33PUL* et de l'année complète pour les trois légendes sur les deux zones d'intérêt *T33PUL* et *T32NPL*. La fusion S-1/S-2 est avantageuse et importante pour gérer les problèmes de forte présence de nuages et ombres sur les images Sentinel-2, surtout sur la zone d'intérêt *T32NPL*. Les résultats du *RF* ont aussi montré des améliorations dans les classifications du mois d'octobre de la classe *AGR* sur la zone d'intérêt *T33PUL* et de la classe *FRT* sur la zone d'intérêt *T32NPL* avec de fortes précisions producteurs. L'utilisation des trois légendes a permis d'atteindre de bons résultats, notamment avec de très fortes précisions producteurs de la classification de l'année complète pour les légendes à 9 et 12 classes sur les zones d'intérêt. Par conséquent, la fusion de classes d'OCS provenant de différentes *BDs* cartographiques ne peut pas permettre d'obtenir des résultats plus précis contrairement à la combinaison de plusieurs *BDs* qui peut conduire à des meilleurs résultats dans les deux zones d'intérêt.

Les dix méthodes de fusion tardive de classifications ont été évaluées qualitativement uniquement sur le jeu de données Sentinel-1_L1/-2_L2A sur deux types de zones rurale et urbaine et pour de petites classes locales sur les zones d'intérêt *T33PUL* et *T32NPL*. De manière générale, les méthodes de fusion par *RF*; *SVM-lin_t0* et *SVM-rbf_t2* n'améliorent pas la détection des classes de la légende à 12 classes sur des zones urbaines des zones *T33PUL* et *T32NPL* respectivement. Dans la représentation de petites classes locales, les fusions des trois méthodes *RF*; *SVM-lin_t0* et *SVM-rbf_t2* donnent de bons résultats pour la légende à 5 classes qui sont meilleurs dans les fusions des méthodes *SVM-lin_t0* sur la zone d'intérêt *T33PUL* et *SVM-rbf_t2* sur la zone d'intérêt *T32NPL*.

Conclusion générale et perspectives

It is good to have an end to journey toward; but it is the journey that matters, in the end.

– Ursula Le Guin (The Left Hand of Darkness, 1969)

Sommaire

6.1	Conclusion générale	297
	6.1.1 Principaux éléments	297
	6.1.2 Contributions et limitations	300
6.2	Perspectives	301
	6.2.1 Perspectives méthodologiques	301
	6.2.2 Perspectives applicatives	303

6.1 Conclusion générale

6.1.1 Principaux éléments

Cette thèse a mis en oeuvre une méthodologie pour la production entièrement automatique des cartes d'OCS à l'échelle d'un pays à l'aide de séries temporelles d'images optiques Sentinel-2 et radar Sentinel-1, fondée sur une classification supervisée utilisant des *BDs* existantes comme données de référence pour l'apprentissage et la validation. L'originalité de la démarche résidait dans l'utilisation de toutes les données images disponibles (pas de sélection de scène en terme de dates appropriées ou de couverture nuageuse), une étape de pré-traitement conduisant à un ensemble homogène de dates d'acquisition sur l'étendue de la zone d'étude (malgré l'utilisation de plusieurs traces satellites et la présence de nuages et leurs ombres) et l'utilisation d'un classifieur supervisé en partie robuste aux erreurs dans les données de référence (*BDs* pouvant par exemple être obsolètes). L'utilisation de différents modèles définis pour des zones d'entraînement plus ou moins étendues s'est avérée apporter des améliorations significatives en terme de reconnaissance des classes d'OCS par rapport à l'entraînement du *RF* sur l'étendue d'une tuile individuelle Sentinel-2.

L'objectif général de la thèse visait à comparer différentes stratégies de production des cartes d'OCS. Trois défis ont été identifiés. Le premier concernait le **choix de la nomenclature (légende)** tandis que le second s'intéressait à la **prise en compte de séries d'images radar** dans le processus de classification

supervisée avec l'algorithme du *RF* et le troisième s'attardait sur la **fusion (tardive) des classifications supervisées** de fusions (précoces) de séries temporelles d'images optiques et radar.

La nomenclature à utiliser devait permettre de trouver un bon compromis entre la qualité des résultats obtenus (classes identifiables à partir des données de télédétection), son intérêt (classes utiles), sa capacité à bien décrire l'OCS des pays mais aussi la faisabilité de constituer un jeu d'entraînement correspondant à partir de diverses *BDs* de « référence » disponibles. Ainsi, l'état de l'art réalisé au Chapitre 3 sur les *BDs* cartographiques a permis de mettre en avant les caractéristiques des trois *BDs* cartographiques *BD OSM*, *BD INC* et *BD GLC* à partir desquelles trois légendes ont été constituées.

En outre, il existe une relation de cause à effet entre la qualité des données à la fois de télédétection (cf. nuages etc.) et de référence et les performances de l'algorithme du *RF*. Un vecteur de variables en entrée doit idéalement contenir une information suffisante et pertinente afin de bien caractériser les différentes classes. Les nouvelles séries temporelles d'images satellitaires ouvrent de nouvelles opportunités mais le choix des variables à extraire de ces données reste un challenge à étudier.

Ainsi, la qualité de la carte produite est directement liée à celle du modèle de l'algorithme du *RF* qui dépend étroitement de la qualité des données fournies. Ainsi, la première partie de la thèse s'interrogeait sur le choix des nomenclatures à utiliser dans le processus de classification, de même que les jeux de données satellitaires à fournir en entrée du système de classification et notamment sur l'impact de l'utilisation des synthèses mensuelles de séries temporelles d'images optiques Sentinel-2_L2A sur les performances de classification du *RF* avec des données de référence très imparfaites.

Le Chapitre 4 a été consacré à l'étude des différentes classifications supervisées réalisées pour chacune des trois légendes préalablement constituées. De plus, la question des jeux de données satellitaires à fournir au système de classification a aussi été abordée. Dans un premier temps, le choix de la nomenclature a été discuté notamment en comparant les performances de classification du *RF* pour chacune des trois légendes. Tout d'abord, la première légende à 5 classes a montré de meilleures performances de l'algorithme du *RF* pour chacune des cinq classes d'OCS en présence comparativement aux deux autres légendes à 9 et 12 classes. Puis, la stabilité du *RF* lors de traitements sur de grandes étendues avec l'utilisation de différents modèles définis pour des zones d'entraînement plus ou moins étendues du *RF* a été abordée. En particulier, les performances de classification ont été évaluées pour chacune des trois légendes, en étendant progressivement la zone d'apprentissage à plusieurs tuiles Sentinel-2, sur des paysages complexes de la zone d'étude *ZONE1*. Cette étude a montré que si la zone d'apprentissage ne comportait pas l'ensemble des éléments physiologiques représentatifs de la zone d'étude *ZONE1* et ne caractérisait pas bien les variabilités des paysages de cette zone d'étude, alors les performances de classification n'étaient pas bonnes. Finalement, le choix des jeux de données satellitaires à fournir en entrée a aussi été étudié pour chacune des trois légendes, en proposant notamment l'utilisation de synthèses mensuelles de séries d'images optiques Sentinel-2_L2A préalablement générées. Ainsi, différentes périodes de synthèse de séries temporelles d'images optiques Sentinel-2_L2A ont été comparées. Il a été vu que l'accroissement de la période de synthèse mensuelle ne permettait pas tant d'améliorer les performances de classification.

Par ailleurs, l'influence des périodes de synthèses mensuelles de séries temporelles d'images optiques sur les performances de classification a été étudiée en comparant **pixel à pixel** et les **distributions de classes** des différentes classifications et fusions de classifications. Pour ce faire, plusieurs expérimentations ont été menées avec chacune des trois légendes et pour chaque période de synthèse

mensuelle générée. Les principaux résultats montraient que l'algorithme du *RF* était performant et robuste pour chacune des trois légendes. Toutefois, la présence de données mal étiquetées au sein des données de référence issues de ces légendes influençait moins les performances de classification du *RF* pour la légende à 5 classes. Par ailleurs, les trois légendes sont impactées négativement par la présence d'un grand nombre de données mal étiquetées.

Le deuxième défi, abordé dans le Chapitre 5 de la thèse, visait la prise en compte de séries d'images radar. Dans un premier temps, l'apport de l'intégration de séries d'images radar Sentinel-1 complémentaires aux séries temporelles d'images optiques Sentinel-2 dans le processus de classification est étudié. Dans un deuxième temps, la fusion (tardive) des différentes classifications est abordée comme une alternative à la classification supervisée de l'OCS. Pour ce faire, un cadre méthodologique a été proposé constitué de la première stratégie (*STR1*) adoptée dans cette thèse ayant pour objectif d'évaluer tout d'abord les différentes classifications d'OCS produites et ensuite les résultats des fusions (tardives) de ces classifications.

Afin de répondre à la première problématique, un ensemble de jeux de données satellitaires et de référence a été étudié au cours du Chapitre 3. L'étude bibliographique montrait que les synthèses mensuelles de séries d'images optiques Sentinel-2_L2A pouvaient être utilisées comme une alternative au *gap-filling* pour passer outre les problèmes de nuages et leurs ombres. De plus, cette étude a montré les limitations des synthèses mensuelles générées pour notre problématique. En particulier, la méthode de génération des synthèses nécessitait la définition d'une fenêtre temporelle. Or, cette période était complexe à définir dans la mesure où il existait des périodes très nuageuses pendant lesquelles les synthèses de niveaux L3A fournissaient des pixels nuageux. Ainsi, nous avons contourné cette difficulté de présence persistante de résidus de nuages en utilisant une méthode d'élimination de nuages qui se fondait sur la durée de la période de synthèse pour espérer avoir une observation claire pour chaque pixel. Dans cette méthode initialement proposée, la moyenne des réflectances de surface calculée reposait sur la période de synthèse. Afin d'éliminer les derniers résidus de nuages et augmenter les chances d'obtenir des observations sans nuages, nous avons également proposé et généré quatre nouvelles périodes de synthèse de séries temporelles d'images optiques.

Au total, cinq périodes de synthèses ont été comparées avec un jeu de données constitué uniquement de séries temporelles d'images optiques Sentinel-2_L2A dans le Chapitre 4. La sensibilité de l'algorithme du *RF* vis-à-vis des différentes périodes de synthèse a été étudiée dans le Chapitre 4. Dans ce chapitre, les principaux résultats des classifications ont montré la bonne performance du *RF* en utilisant les synthèses mensuelles de 165 jours de périodes (*P165*) et plus ayant permis d'éliminer au maximum les derniers résidus de nuages qui subsistaient sur les séries d'images optiques. Par ailleurs, les méthodes de fusion (précoce), couramment utilisées dans la littérature, ont montré également leur capacité à supprimer la quasi-totalité des nuages sur les séries d'images. Cependant, ces méthodes ne permettaient pas de passer outre la présence d'une grande quantité de nuages sur les images puisqu'elles appliquaient pour la plupart la propriété du *gap-filling* au terme de laquelle il existait toujours quelques petits nuages ou ombres qui arrivaient à échapper à la détection au niveau L2A.

Le Chapitre 4 a donc montré que l'utilisation des synthèses amélioraient les performances de classification du *RF*. Ainsi, ces synthèses mensuelles pouvaient être utilisées dans un cadre méthodologique permettant de minimiser les artefacts habituellement visibles sur les images. La solution choisie et mise en oeuvre au Chapitre 5 consistait à effectuer une première étape de classification de fusions (précoces)

de séries temporelles d'images optiques et radar afin d'exploiter les propriétés provenant de chacune de ces deux types d'images. Une autre piste investiguée à consister à appliquer une deuxième étape de fusion (tardive) des différentes classifications produites mensuellement dans le but de s'affranchir davantage des erreurs de classification et d'améliorer la qualité des cartes d'OCS produites.

Dans ce contexte, le Chapitre 5 a présenté plusieurs méthodes de fusion (tardive), fondées notamment sur les caractéristiques des données de télédétection du Chapitre 3 et les différentes fusions (précoces) classifiées au Chapitre 4. Certaines méthodes de fusion (tardive) déjà existantes ont été étudiées et adaptées à notre problématique. Les méthodes de fusion (tardive) proposées utilisaient, ici, la combinaison d'images optiques et radar, différentes règles et méthodes de fusion, différents classifieurs utilisés pour la fusion supervisée.

Les principaux résultats ont montré que les différentes méthodes de fusion (tardive) supervisée appliquées permettaient d'obtenir une cartographie précise de l'OCS en améliorant la qualité des résultats. Les évaluations quantitative et qualitative ont été menées, les résultats ont alors montré que les méthodes de fusion supervisée permettaient d'obtenir des meilleures qualités de cartes OCS par rapport aux simples classifications supervisées avec l'algorithme du *RF*. Une analyse approfondie sur les différentes fusions (tardives) a montré des comportements différents. Certaines méthodes de fusion supervisée fondées sur l'apprentissage, qui consistaient à apprendre comment fusionner au mieux deux sources de données, donnaient de bons résultats dans des cas où toutes les classes n'avaient initialement pas été identifiées par la classification. Pour résumer, le Chapitre 5 a donc mis en évidence que les méthodes de fusion supervisée des classifications supervisées étaient une solution possible et pertinente pour améliorer la qualité des différentes classifications de l'OCS.

6.1.2 Contributions et limitations

Notre principale contribution était la proposition d'une méthode générique de multiplication des classifications à l'aide de la chaîne *iota*², nommée *Multi Source, Multi Configuration, Multi Fusion Method* qui permettait, d'une part, la classification de configurations de *BDs* complexes dont les classes possédaient différentes apparences et, d'autre part, un apprentissage avec des données de référence contenant des données mal étiquetées (pouvant venir d'un éventuel décalage entre l'image et la *BD*).

La seconde contribution de ce travail était l'intégration de la méthode précédente dans une chaîne de traitements permettant de s'adapter automatiquement aux différentes configurations de *BDs* à mettre à jour.

Par ailleurs, nous avons pu étudier les capacités des images Sentinel-1 et Sentinel-2 sur nos problèmes. En particulier, nous avons montré que les attributs spectral et temporel permettaient de définir et de caractériser l'objet d'une manière précise et complète. En effet, les techniques de classification supervisée avec l'algorithme du *RF* qui prenaient en compte un mécanisme interne de sélection d'attributs pourraient préférer la source de données générant le plus grand nombre d'attributs en cas de déséquilibre d'ensembles de primitives. En particulier, ces attributs ne permettaient pas au processus de fusion de bénéficier pleinement des avantages de tous les jeux de données même avec des stratégies de sélection de primitives.

De plus, notre méthode nécessitait de produire davantage des classifications avec un grand nombre d'attributs afin de gagner en généricité et en robustesse. Par conséquent, même s'ils restaient acceptables, les temps de calcul liés à ces différentes étapes devront être réduits afin d'envisager son passage

à l'échelle. Ainsi, nous avons vu dans cette section, ce dont notre méthode était capable, ses points forts, ainsi que ses faiblesses. Dans la section suivante, nous proposerons d'une part, un ensemble d'idées d'amélioration qui pourrait permettre de réduire les points faibles de la méthode (perspectives méthodologiques) et d'autre part, les différentes applications connexes rendues possibles par notre méthode (perspectives applicatives).

6.2 Perspectives

6.2.1 Perspectives méthodologiques

Plusieurs perspectives méthodologiques pourraient être envisagées en lien avec les trois défis abordés dans la thèse. Ainsi, elles pourraient concerner le choix des données satellitaires, le choix de la nomenclature, ou encore les méthodes de fusion (tardive) des classifications supervisées.

Dans ces travaux, les données fournies en entrée du système de classification se résumaient aux bandes spectrales ainsi qu'aux primitives spectrales. Toutefois, il serait possible d'ajouter des primitives temporelles et un plus grand nombre de primitives utilisant notamment le contexte spatial. De même l'utilisation d'approches fondées sur des objets ou des super-pixels pourrait permettre d'une part de consommer moins de mémoire et de réduire les confusions observées au Chapitre 4 pour les légendes à 9 et 12 classes. Même si l'ajout des données radar Sentinel-1 complémentaires aux données optiques Sentinel-2 ont permis de s'affranchir des mauvaises conditions lors des acquisitions avec des capteurs passifs (BALZTER et al., 2015; INGLADA, 2016b; KUSSUL et al., 2017), l'exploitation de la synergie de ces deux types d'images sur de grandes étendues (INGLADA, 2016b; WASKE et BENEDIKTSSON, 2007b; WASKE et LINDEN, 2008) a conduit à la prise en compte de nouvelles variables dans le processus de classification.

Cependant, la prise en compte de ces variables pourrait occasionner de nouvelles problématiques liées notamment à la très grande dimension du problème de classification et à la gestion des gros volumes de données. Ainsi, étudier des **méthodes de sélection ou de réduction du volume des données telles que les méthodes consistant à regrouper les données qui pourraient se ressembler et celles pouvant permettre de réduire le nombre de descripteurs en entrée pourrait être intéressant dans des futurs travaux**. Cela pourra permettre d'une part d'assurer le bon fonctionnement des algorithmes de classification et d'autre part de réduire le temps d'apprentissage de ces algorithmes (DUMEUR, VALERO et INGLADA, May 2023) dans la chaîne de traitement *iota*².

Concernant le choix de la nomenclature à utiliser pour la classification, la légende à 12 classes a montré son intérêt dans le contexte de la classification de séries temporelles d'images satellitaires. Toutefois, certaines limitations ont aussi pu être constatées au cours des différentes études. Par exemple, des performances très faibles sont obtenues dans le Chapitre 4 pour les classes sous-représentées (e.g. la classe RIV) ou les classes difficiles à classifier présentant de forte variabilité (e.g. la classe PRA). Une solution pour ces classes plus difficiles pourrait consister à combiner les performances de différents algorithmes de classification dans la chaîne *iota*². Par exemple, les résultats du Chapitre 4 ont montré qu'en testant des modèles d'entraînement issus de différents algorithmes de classification comme par exemple l'algorithme du SVM en complément à l'algorithme du RF dans la chaîne *iota*², les résultats pourraient s'améliorer. De plus, les primitives temporelles n'ont pas été calculées dans ces travaux avec pour idée d'essayer d'exploiter cette information.

Par ailleurs, le Chapitre 4 a mis en évidence les difficultés de la classification sur les zones de montagne et de manière générale sur la zone d'étude *ZONE1* présentant des caractéristiques différentes de celles de la zone d'apprentissage du modèle d'entraînement. La mise en place d'une stratification en modèles définis pour des zones d'entraînement plus ou moins étendues en fonction des caractéristiques des paysages et des tuiles Sentinel-2 pourrait être appropriée lors de traitements sur de grandes étendues.

En classification supervisée, il est courant de diviser les données de référence en deux sous-ensembles : le premier est constitué des échantillons d'apprentissage utilisés pour apprendre le classifieur tandis que le second est constitué des échantillons de validation utilisés pour évaluer la classification. Ainsi, la présence de données mal étiquetées pourrait impacter à la fois les étapes d'apprentissage et de validation et influencer ainsi les performances de la classification. Les travaux de cette thèse s'intéressaient uniquement aux conséquences de la présence de données mal étiquetées dans les échantillons d'apprentissage tandis que d'autres travaux considéraient uniquement la présence de données mal étiquetées dans les échantillons de validation (CONGALTON et GREEN, 2008; FOODY, 2002; FOODY, 2013). Il serait intéressant d'avoir une réflexion poussée de ces études afin de les enrichir en analysant la présence de données mal étiquetées à la fois dans les échantillons d'apprentissage et de test. Cette étude permettrait entre autre de comparer les résultats respectifs des étapes de classification et de validation.

Concernant le deuxième défi abordé dans cette thèse, le Chapitre 5 a montré que les méthodes de fusion supervisée par apprentissage de classifieurs amélioraient à la fois les performances et la qualité de la classification. Néanmoins, les performances maximales n'étaient pas atteintes pour les méthodes de fusion par apprentissage des classifieurs *SVM-linéaire* et *SVM-rbf*. Cette limitation pourrait être due au fait que les méthodes de fusion supervisée par apprentissage avec ces classifieurs proposées supprimeraient quelques échantillons correctement étiquetés, informatifs pour le problème de classification.

Après application des règles de fusion au niveau du pixel, il pourrait être avantageux d'adopter une stratégie de régularisation globale (HERVIEU, LE-BRIS et MALLET, 2016) des cartes de fusion obtenues. Le problème pourrait être exprimé à l'aide d'un modèle probabiliste graphique. En effet, une telle formulation a été utilisée avec succès dans de nombreux sujets liés au traitement d'images au cours des dernières années (KOLMOGOROV et ZABIH, 2004). Dans notre problématique, l'idée serait de traiter les incertitudes spatiales entre deux sources de données. En effet, le résultat de la fusion pourrait contenir encore des bruits notamment dans des zones de transition entre classes voisines. En outre, compte tenu de l'information de l'image d'origine, une telle régularisation pourrait permettre également de rapprocher les contours de la réalité.

De plus, la régularisation se fondant sur les interactions entre un pixel donné et son voisinage, une contrainte de lissage de la carte de classification initiale pourrait être fixée. Ainsi, plusieurs options fondées sur des modèles utilisant des paramètres d'optimisation pourraient être considérées visant à améliorer la qualité visuelle et l'interprétabilité des résultats de classification dans des contextes opérationnels.

Enfin, un aspect important à considérer dans ces travaux serait l'adaptation des méthodes proposées pour pouvoir être appliquées sur un grand nombre d'échantillons. En effet, les configurations étudiées dans ces travaux se limitaient à un faible nombre d'échantillons alors que la classification

sur de grandes étendues pourrait nécessiter un grand nombre d'échantillons. Il conviendrait de noter qu'atteindre des précisions d'environ 90 % pourrait être suffisant pour les cartes d'OCS statiques mais serait presque inutile dans le cadre de l'analyse des changements d'OCS au niveau du pixel en se fondant sur le fait que la plupart des classes aurait un très faible taux de variation. Dans ce cas, la comparaison des cartes d'OCS d'années successives ne permettrait pas de détecter avec précision les évolutions de l'OCS. Par conséquent, il serait donc important d'adapter les méthodes étudiées aux changements précis de la couverture terrestre.

6.2.2 Perspectives applicatives

Dans ces travaux, des méthodes de fusion (tardive) des classifications supervisées sont proposées pour améliorer les résultats de classification. La première application directe de ces travaux serait l'obtention de cartes d'OCS précises sur de grandes étendues. Par exemple, les données de l'OCS pourraient être utilisées pour des applications en météorologie ou pour la détection des zones de changements sans que l'OCS ne soit nécessairement connue au pixel près. De manière similaire, les approches proposées pourraient être utilisées lorsque les étiquettes des échantillons d'apprentissage seraient extraites de n'importe quelle carte d'OCS produite sur de grandes étendues.

Une deuxième application serait la production de cartes d'OCS de l'année en cours en utilisant des données de référence collectées les années précédentes (TARDY, [December 2019](#)). Ces cartes pourraient alors être utiles dans des applications réelles nécessitant un suivi régulier des territoires et une mise à jour cartographique régulière.

Finalement proposée pour améliorer les résultats des classifications supervisées produites, la fusion (tardive) de ces classifications pourrait ouvrir de nouvelles perspectives pour l'identification des zones de changement dans les *BDs* d'OCS. En effet, les classifications supervisées de l'OCS à partir d'images satellitaires suivies de leur fusion pourraient permettre d'identifier aisément des zones de changement d'OCS sachant que l'on ne pourrait pas atteindre certains objets tels que les bâtiments. Dans le cadre de cette application, l'utilisation d'ortho-images générées conjointement avec des *MNS* à partir de prises de vues numériques d'images aériennes à *THR* spatiale pourrait permettre de déceler le lien entre une orthophotographie et une image satellite (surtout Sentinel-2) et d'étudier la possibilité d'existence d'un modèle statistique permettant de passer de l'une à l'autre et vis versa. En outre, ces ortho-images pourraient être exploiter dans un processus d'apprentissage profond. Au terme des travaux, on pourrait également envisager d'extraire manuellement d'autres polygones de classes d'OCS dans le but de compléter et d'enrichir les données de référence et de reprendre ensuite le même processus de classification dans la chaîne de traitement *iota*² (*active learning*).

- ACHARD, F. et al. (2002). « Determination of deforestation rates of the world's humid tropical forests ». In : *Science* 297.5583, 999–1002.
- ACHARD, F. et al. (2006). « Determination of deforestation rates of the world's humid tropical forests ». In : *Science* 297, p. 999-1003.
- AGYEI, Y. (1998). « Deforestation in Sub-Saharan Africa. African Technology Forum ». In : 8.1. URL : <http://web.mit.edu/africantech/www/articles/Deforestation.htm> Accessed on 08 March, 2017.
- AKBANI, R., S. KWEK et N. JAPKOWICZ (2004). « Applying support vector machines to imbalanced datasets ». In : *European Conference on Machine Learning (ECML)*, pages 39-50.
- AKBARI, M. et al. (2006). « Crop and land cover classification in Iran using Landsat 7 imagery ». In : *Journal of Remote Sensing* 27.19, p. 4117-4135.
- AKUBIA, J. E. (2016). « Coastal Urbanization and Urban Land-use change in the Greater Accra Metropolitan Area, Ghana. Governance and Sustainability Lab. Trier University ». In : *Water Power Working Paper* 10.
- ANDERSON, R. R. et F. J. WOBBER (1973). « wetlands mapping in New Jersey ». In : *Photogrammetric Engineering* 39.4, pp 353-358.
- ANTONIOU, V. et A. SKOPELITI (2015). « Mesures et indicateurs de la qualité de l'IGV : Un aperçu ». In : *ISPRS Int J Geo-Inf* Vol. II-3/W5, p. 345–351.
- APPRIOU, A. (1991). « Probabilités et incertitude en fusion de données multi-senseurs ». In : *Revue Scientifique Et Technique de la Défense* 11, 27–40.
- ARIAS, M. et D. MORIN (2017). « Vector-Tools-7ab2125a. 2016. ». In : URL : http://tully.upstlse.fr/jordi/vector_tools (accessed on 18 January 2017).
- ARINO, O. et al. (2007). « GlobCover : ESA service for global land cover from MERIS ». In : *IEEE International Geoscience and Remote Sensing Symposium 2007 (IGARSS)*, pages 2412-2415. IEEE.
- ARSANJANI, J. J. et al. (2015). « Quality assessment of the contributed land use information from openstreetmap versus authoritative datasets ». In : *OpenStreetMap in GIScience*, pages 37-58.
- ARVOR, D. et al. (2011). « Classification of MODIS EVI time series for crop mapping in the state of Mato Grosso, Brazil ». In : *International Journal of Remote Sensing* 32.22, p. 7847-7871.
- ATANGANA, J. N. et al. (2010). « Evaluation environnementale de la problématique de bois de feu dans la ville de Garoua Nord Cameroun ». In : *Colloque SIFEE*.
- AUDEBERT, N., B. Le SAUX et S. LEFÈVRE (2017). « Fusion of heterogeneous data in convolutional networks for urban semantic labeling ». In : *Proc. of the Joint Urban Remote Sensing Event, JURSE*.
- AUER, M. et al. (2018). « Vers l'utilisation du potentiel de l'historique OpenStreetMap pour la surveillance de l'activation des catastrophes ». In : *Actes de la 15ème Conférence ISCRAM*, p. 317–25.
- BACCINI, A. et al. (2008). « A first map of tropical Africa's above-ground biomass derived from satellite imagery ». In : *Environmental Research Letters* 3.4, p. 045011.
- BAGHDADI, N. et M. ZRIBI (2016). « Observation des surfaces continentales par télédétection I – Agriculture et forêt ». In : *Londres, Grande Bretagne : ISTE Editions Ltd* Volume 3, 454 p.
- BAI, Y. et al. (2014). « "Assessing Consistency of Five Global Land Cover Data Sets in China." » In : *Remote Sensing* 6, 8739–8759.
- BAIG, M. H. A. et al. (2014). « Derivation of a tasseled cap transformation based on Landsat 8 at-satellite reflectance ». In : *Remote Sensing Letters* 5.5, p. 423-431.

- BALZTER, H. et al. (2015). « Mapping CORINE land cover from Sentinel-1A SAR and SRTM digital elevation model data using Random Forests ». In : *Remote Sensing* 7.11, p. 14876-14898.
- BAMOU, E. et A. W. MASTERS (2007). « Distortions to Agricultural Incentives in Cameroon : Agricultural Distortions. World Bank, Washington, DC. » In : *Working Paper* 42, 158–167.
- BARRINGTON-LEIGH, C. et A. MILLARD-BALL (2017). « La feuille de route mondiale générée par les utilisateurs est complète à plus de 80 % ». In : *PLOS ONE* 12.8, p. 0180698.
- BARRON, C., P. NEIS et A. ZIPF (2014). « Un cadre complet pour l'analyse intrinsèque de la qualité OpenStreetMap : Un cadre complet pour l'analyse intrinsèque de la qualité OpenStreetMap ». In : *Trans SIG* 18.6, 877–95.
- BARTHOLOMÉ, E. et A. S. BELWARD (2005). « GLC2000 : a new approach to global land cover mapping from Earth observation data ». In : *International Journal of Remote Sensing* 9, p. 1959-1977.
- BARTHOLOMÉ, E. et al. (2002). « GLC 2000 : Global Land Cover mapping for the year 2000 ». In : *EUR 20524 EN, European Commission, Luxembourg*.
- BAUER, E. et R. KOHAVI (1999). « An empirical comparison of voting classification algorithms : Bagging, boosting, and variants ». In : *Machine Learning* 36.1, p. 105-139.
- BECK, P. S. A. et al. (2006). « Improved monitoring of vegetation dynamics at very high latitudes : A new method using MODIS NDVI ». In : *Remote Sensing of Environment* 100.3, p. 321-334.
- BELGIU, M. et L. DRĂGUȚ (2016). « Random Forest in remote sensing : A review of applications and future directions ». In : *ISPRS Journal of Photogrammetry and Remote Sensing* 114, p. 24-31.
- BELWARD, A. S., J. E. ESTES et K. D. KLINE (1999). « The igbp-dis global 1-km land-cover data set discover : A project overview ». In : *Photogrammetry Engineering and Remote Sensing* 65.9, p. 1013-1020.
- BENEDIKTSSON, J. et I. KANELLOPOULOS (1999). « Decision fusion methods in classification of multi-source and hyperdimensional data ». In : *IEEE Transactions on Geoscience and Remote Sensing* 37.3, 1367–1377.
- BERGER, C. et al. (2013). « Multi-modal and multitemporal data fusion : outcome of the 2012 GRSS Data Fusion Contest ». In : *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing* 6.3, 1324–1340.
- BERNARD, S., L. HEUTTE et S. ADAM (2009). « Influence of hyperparameters on random forest accuracy ». In : *International Workshop on Multiple Classifier Systems*, pages 171-180.
- BLASCHKE, T. (2010). « Object based image analysis for remote sensing ». In : *ISPRS Journal of Photogrammetry and Remote Sensing* 65.1, p. 2-16.
- BLOCH, I. (1996). « Information combination operators for data fusion : a comparative review ». In : *IEEE Transactions on Systems, Man and Cybernetics* 26.1, 52–67.
- (2003). « Fusion d'informations en traitement du signal et des images ». In : *Édition Hermès Science, paris, France*, 319 p.
- BOJINSKI, S. et al. (2014). « The concept of essential climate variables in support of climate research, applications, and policy. » In : *Bulletin of the American Meteorological Society* 95.9, p. 1431-1443.
- BONN, F. et G. ROCHON (1992). « Précis de télédétection volume 1 : Principes et méthodes ». In : *SainteFoy : Presse de l'université du Québec/AUPELF*, 485 p.
- BONTEMPS, S. et al. (2015). « Multi-year global land cover mapping at 300 m and characterization for climate modelling : Achievements of the Land Cover component of the ESA Climate Change Initiative ». In : *The International Archives of Photogrammetry, Remote Sensing and Spatial Information Sciences* 40.7, p. 323.
- BORRE, J. Vanden et al. (2011). « Integrating remote sensing in Natura 2000 habitat monitoring : Prospects on the way forward ». In : 19, 116–125.

- BREIMAN, L. (1996). « Bagging predictors ». In : *Machine Learning* 24.2, p. 123-140.
- (2001). « Random Forests ». In : *Machine Learning* 45.1, p. 5-32.
- BREIMAN, L. et al. (1984). « *Classification and regression trees* ». In : *Taylor & Francis*.
- BRIEM, G. J., J. A. BENEDIKTSSON et J. R. SVEINSSON (2002). « Multiple classifiers applied to multisource remote sensing data ». In : *IEEE Transactions on Geoscience and Remote Sensing* 40.10, p. 2291-2299.
- BROVELLI, M. A. et al. (2016). In : *Archives internationales de la photogrammétrie, de la télédétection et des sciences de l'information spatiale* 41, 615-20.
- BROVELLI, M. A. et al. (2017). « Vers une comparaison automatisée d'OpenStreetMap avec des ensembles de données routières faisant autorité ». In : *Trans SIG* 21.2, p. 191-206.
- BROWN, C. F., S. P. BRUMBY et B. GUZDER-WILLIAMS (2022). « Dynamic World, Near real-time global 10m land use land cover mapping ». In : *Sci Data* 9, p. 251. URL : <https://doi.org/10.1038/s41597-022-01307-4>.
- BROWN, C. F. et al. (2022). « Dynamic World, Near real-time global 10m land use land cover mapping ». In : *Scientific Data* 9.251.
- BROWN, G. et al. (2005). « Diversity creation methods : a survey and categorisation ». In : *Information Fusion* 6.1, p. 5-20.
- BROXTON, P. D. et al. (2014). « A global land cover climatology using MODIS data ». In : *Journal of Applied Meteorology and Climatology* 53.6, p. 1593-1605.
- BRYLL, R., R. GUTIERREZ-OSUNA et F. QUEK (2003). « Attribute bagging : improving accuracy of classifier ensembles by using random feature subsets ». In : *Pattern Recognition* 36.6, p. 1291-1302.
- BUCHHORN, M. et al. (2020). « Copernicus Global Land Service : Land Cover 100m : collection 3 : epoch 2018 : Globe 2020. » In : URL : [DOI10.5281/zenodo.3518038](https://doi.org/10.5281/zenodo.3518038).
- BURGESS, N. D. et al. (2010). « Getting ready for REDD+ in Tanzania : a case study of progress and challenges ». In : *Oryx* 44.03, p. 339-351.
- BÜTTNER, G. (2014). « CORINE land cover and land cover change products ». In : *Land Use and Land Cover Mapping in Europe*, pages 55-74. Springer.
- CAMPS-VALLS, G. et al. (2011). « *Remote Sensing Image Processing* ». In : *Synthesis Lectures on Image, Video, and Multimedia Processing*.
- CANAVOSIO-ZUZELSKI, R., P. AGOURIS et P. DOUCETTE (2013). « Une approche photogrammétrique pour évaluer la précision de positionnement des routes OpenStreetMap ». In : *SPRS Int J Geo-Inf* 2.2, p. 276-301.
- CAO, Y., H. LEE et H. KWON (2018). « Enhanced object detection via fusion with prior beliefs from image classification ». In : *arXiv preprint arXiv :1610.06907*.
- CARLOTTO, M. J. (2009). « Effect of errors in ground truth on classification accuracy ». In : *International Journal of Remote Sensing* 30.18, p. 4831-4849.
- CARRÃO, H., P. GONÇALVES et M. CAETANO (2008). « Contribution of multispectral and multitemporal information from MODIS images to land cover classification ». In : *Remote Sensing of Environment* 112.3, p. 986-997.
- CARUANA, R. et A. NICULESCU-MIZIL (2006). « An empirical comparison of supervised learning algorithms ». In : *International Conference on Machine Learning Research (ICML)*, pages 161-168, ACM.
- CEAMANOS, X. et al. (2010). « A classifier ensemble based on fusion of support vector machines for classifying hyperspectral data ». In : *International Journal of Image and Data Fusion* 1.4, 293-307.
- CHAVEZ, S. et al. (1991). « Comparison of three different methods to merge multiresolution, multispectral data Landsat TM and SPOT panchromatic ». In : *Photogrammetric Engineering and Remote Sensing* 57.3, p. 259-303.

- CHAVEZ-GARCIA, R. O. et O. AYCARD (2016). « Multiple sensor fusion and classification for moving object detection and tracking ». In : *IEEE Transactions on Intelligent Transportation Systems* 17.2, 525–534.
- CHAWLA, N. V. (Springer, 2005). « Data mining for imbalanced datasets : An overview ». In : *Data Mining and Knowledge Discovery Handbook*, pages 853-867.
- CHEN, C., A. LIAW et L. BREIMAN (2004). « Using Random Forest to learn imbalanced data ». In : *University of California* 110.
- CHEN, J. et al. (2015a). « Global land cover mapping at 30m resolution : A POK-based operational approach ». In : *ISPRS J. Photogramm. Remote Sens.* 103, 7–27.
- CHEN, J. et al. (2015b). « Global land cover mapping at 30m resolution : A POK-based operational approach ». In : *ISPRS Journal of Photogrammetry and Remote Sensing* 103, p. 7-27.
- CIEPLUCH, B., P. MOONEY et A. C. WINSTANLEY (2011). « Construire des indicateurs de qualité génériques pour openstreetmap ». In : *Actes de la 19e conférence annuelle de GIS Research UK (GISRUK 2011)*.
- CLAVERIE, M. et al. (2012). « Maize and sunflower biomass estimation in southwest France using high spatial and temporal resolution remote sensing data ». In : *Remote Sensing of Environment* 124, p. 844-857.
- COLDITZ, R. R. (2015). « An evaluation of different training sample allocation schemes for discrete and continuous land cover classification using decision tree-based algorithms ». In : *Remote Sensing* 7.8, p. 9655-9681.
- COMBER, A. et al. (2012). « Spatial analysis of remote sensing image classification accuracy ». In : *Remote Sensing of Environment* 127, p. 237-246.
- CONGALTON, G. R. et al. (2014). « “Global Land Cover Mapping : A Review and Uncertainty Analysis.” » In : *Remote Sensing* 6, 12070–12093.
- CONGALTON, R. G. (1991). « A review of assessing the accuracy of classifications of remotely sensed data ». In : *Remote Sensing of Environment* 37, p. 35-46.
- CONGALTON, R. G. et K. GREEN (2008). « Assessing the accuracy of remotely sensed data : principles and practices ». In : *CRC press*.
- CORCORAN, P., P. MOONEY et M. BERLOLOTTO (2013). « Analyse de la croissance des réseaux OpenStreetMap ». In : *Statistique de naissain* 3, 21–32.
- COWARDIN, L. M. et V. I. MYERS (1974). « Remote sensing for identification and classification of wetland vegetation ». In : *The journal of wildlife* 38.2, pp 308-314.
- CRIST, E. P. et R. C. CICONE (1984). « A physically-based transformation of Thematic Mapper data – The TM Tasseled Cap ». In : *IEEE Transactions on Geoscience and Remote Sensing* GE-22.3, p. 256-263.
- DANIELSEN, F. et al. (2011). « At the heart of REDD+ : a role for local people in monitoring forests ? » In : *Scientific Data* 4.2, 158–167.
- DASH, J. et al. (2007). « Land cover classification using multi-temporal MERIS vegetation indices ». In : *International Journal of Remote Sensing* 28.6, p. 1137-1159.
- DECHESNE, C. et al. (2017). « Semantic segmentation of forest stands of pure specie as a global optimisation problem ». In : *ISPRS Annals of Photogrammetry, Remote Sensing and Spatial Information Sciences* 4.1/W1, 141–148.
- DEFOURNY, P. et al. (2006). « GlobCover : a 300 m global land cover product for 2005 using ENVISAT MERIS time series ». In : *Proceedings of the ISPRS Commission VII mid-term symposium, Remote sensing*, pages 8-11. Citeseer.
- DEFRIES, R. S., G. P. ASNER et R. A. HOUGHTON (2004). « Ecosystems and Land Use Change. Geophysical Monograph ». In : *Washington, DC : American Geophysical Union* 153.

- DEFRIES, R. S. et J. R. G. TOWNSHEND (1994). « NDVI-derived land cover classification at a global scale ». In : *International Journal of Remote Sensing* 15.17, p. 3567-3586.
- DENG, X. et J. LIU (CRC Press : Boca Raton, FL, USA, 2012). « Mapping land cover and land use changes in China ». In : *Remote Sensing of Land Use and Land Cover : Principles and Applications*, pp. 339-349.
- DERIBEW, K. T. et D. W. DALACHO (2019). « Land use and forest cover dynamics in the North-Eastern Addis Ababa, central Highlands of Ethiopia ». In : *Environmental Systems Research* 8.8.
- DEVILLERS, R. et R. JEANSOULIN (2010). « Qualité des données spatiales : concepts ». In : *Hoboken : Bibliothèque en ligne Wiley*, p. 31-42.
- DEZERT, J. (2013). « Fondations pour une nouvelle théorie du raisonnement plausible et paradoxal : application à la fusion d'informations incertaines et conflictuelles ». In : *Technical Report 1/06769 DTIM, Tech. rep.*
- DIETTERICH, T. G. (2000a). « Ensemble methods in machine learning ». In : *International Workshop on Multiple Classifier Systems*, pages 1-15. Springer.
- DITUS, M., G. QUATTRONE et L. CAPRA (2017). « Participation de masse lors d'une intervention d'urgence : crowdsourcing événementiel dans la cartographie humanitaire ». In : *Actes de la conférence ACM 2017 sur le travail coopératif assisté par ordinateur et l'informatique sociale - CSCW '17. New York : ACM Press*, p. 1290-303.
- DU, P. et al. (2012). « Multiple classifier system for remote sensing image classification : A review ». In : *Sensors* 12.4, p. 4764-4792.
- DUBOIS, D. et H. PRADE (1992). « Combination of fuzzy information in the framework of possibility theory ». In : *M. A. Abidi, R. C. Gonzalez (Eds.)*, pp. 481-505.
- (1997). « Possibility theory and data fusion in poorly informed environment ». In : *Control Engineering Practice* 2, 811-823.
- DUMEUR, I., S. VALERO et J. INGLADA (May 2023). « Self-supervised spatio-temporal representation learning of Satellite Image Time Series. 2023 ». In : URL : <http://hal.univ-lorraine.fr/RESEAU-TELEDETECTION-INRAE/hal-04084839v1>.
- EERENS, H. et al. (2014). « Image time series processing for agriculture monitoring ». In : *Environmental Modelling Software* 53, p. 154-162.
- EFRON, B. et R. J. TIBSHIRANI (1994). « *An introduction to the bootstrap* ». In : *CRC press*.
- ELACHI, C. (1988). « Spaceborne radar remote sensing : applications and techniques ». In : *New York, IEEE Press*, 285 p.
- ELLIS, E. et R. PONTIUS (2007). « "Land-Use and Land-Cover Change." » In : *Encyclopedia of Earth, edited by C. J. Cleveland. Washington, DC : Environmental Information Coalition, National Council for Science and the Environment. Accessed September 28, 2014. URL : http://www.eoearth.org/article/Land-use_and_land-cover_change.*
- ESTABROOKS, A., T. JO et N. JAPKOWICZ (2004). « A multiple resampling method for learning from imbalanced data sets ». In : *Computational Intelligence* 20.1, p. 18-36.
- ESTIMA, J. et M. PAINHO (2013). « Exploratory analysis of OpenStreetMap for land use classification ». In : *ACM International Workshop on Crowdsourced and Volunteered Geographic Information (SIGSPATIAL)*, pages 39-46. ACM.
- (2015). « Étudier le potentiel d'openstreetmap pour l'utilisation des terres/la production d'occupation des sols : une étude de cas pour le portugal continental ». In : *OpenStreetMap dans GIScience. Cham : Springer*, p. 273-293.
- EVA, H. D. et al. (2004). « A land cover map of South America ». In : *Global Change Biology* 10.5, p. 731-744.

- FAN, H. et al. (2014). « Évaluation de la qualité des données d'empreintes de bâtiments sur OpenStreetMap ». In : *Int J Geogr Inf Sci* 28.4, 700–19.
- FAO (2008). « Land Cover Activities in the SADC Region ». In : *Tech. rep. GLCN Rome*.
- (2010b). « Global Forest Resources Assessment 2010 : Key Findings ». In : *FAO Forestry Paper* 106.4, p. 12.
- (2010c). « Global Forest Resources Assessment 2010 : Main Report ». In : *FAO Forestry Paper* 147, 350 pp.
- (2011). « The State of the World's Forests. Rome ». In : *Scientific Data*. URL : <http://www.fao.org/docrep/013/i2000e/i2000e00.htm>.
- FAUVEL, M., J. CHANUSSOT et J. BENEDIKTSSON (2006). « Decision fusion for the classification of urban remote sensing images ». In : *IEEE Transactions on Geoscience and Remote Sensing* 44.10, 2828–2838.
- FAUVEL, M. et al. (2007). « Spectral and spatial classification of hyperspectral data using SVMs and morphological profiles ». In : *Proc. of the IEEE International Geoscience and Remote Sensing Symposium*, pp. 4834–4837.
- FEDDEMA, J. J. et al. (2005). « The importance of land-cover change in simulating future climates ». In : *Science* 310.5754, p. 1674-1678.
- FERANEC, J. et al. (2007). « “Corine Land Cover Change Detection in Europe (Case Studies of the Netherlands and Slovakia).” » In : *Land Use Policy* 24, 234–247.
- FERNÁNDEZ-DELGADO, M. et al. (2014). « Do we need hundreds of classifiers to solve real world classification problems? » In : *Journal of Machine Learning Research* 15.1, p. 3133-3181.
- FILIPPONI, F. (2019). « Repository-Sentinel-1GRDpreprocessing : StandardWorkflowforthePreprocessingofSentinel – 1GRDSatelliteData. ». In : *Available on-line* : <https://github.com/ffilipponi/Sentinel-1GRDpreprocessing..>
- FONTE, C. C. et al. (2017). « Utilisation d'openstreetmap pour créer des cartes d'utilisation et d'occupation du sol : Développement d'une application ». In : *Information géographique volontaire et l'avenir des données géospatiales. Hershey, Pennsylvanie : IGI Global*, p. 113–137.
- FOODY, G. et al. (2017). « Mapping and the Citizen Sensor ». In : *Cartographie et capteur citoyen. Londres : Ubiquity Press*, p. 1-12.
- FOODY, G. M. (1992). « On the compensation for chance agreement in image classification accuracy assessment ». In : *Photogrammetric Engineering and Remote Sensing* 58.10, p. 1459-1460.
- (2002). « Status of land cover classification accuracy assessment ». In : *Remote Sensing of Environment* 80.1, p. 185-201.
- (2009). « Classification accuracy comparison : hypothesis tests and the use of confidence intervals in evaluations of difference, equivalence and non-inferiority ». In : *Remote Sensing of Environment* 113.8, p. 1658-1663.
- (2013). « Ground reference data error and the mis-estimation of the area of land cover change as a function of its abundance ». In : *Remote Sensing Letters* 4.8, p. 783-792.
- FOODY, G. M. et A. MATHUR (2004a). « A relation evaluation of multiclass image classification by Support Vector Machines ». In : *IEEE Transactions on Geoscience and Remote Sensing* 42.6, p. 1335-1343.
- (2004b). « Toward intelligent training of supervised image classification : directing training data acquisition for svm classification ». In : *Remote Sensing of Environment* 93.1, p. 107-117.
- (2006). « The use of small training sets containing mixed pixels for accurate hard image classification : Training on mixed spectral responses for classification by a SVM ». In : *Remote Sensing of Environment* 103.2, p. 179-189.

- FOODY, G. M. et al. (2016). « The sensitivity of mapping methods to reference data quality : Training on mixed spectral responses for classification by a SVM ». In : *ISPRS International Journal of Geo-Information* 5.11, p. 199.
- FRAM, C., K. CHISTOPOULOU et C. ELLUL (2015). « Évaluation de la qualité des données de construction openstreetmap et recherche d'une variable proxy pour estimer l'exhaustivité des données de construction osm ». In : *Actes du GIS Research UK (GISRUK)*, p. 195–205.
- FRANKLIN, J. (1998). « Predicting the distribution of shrub species in southern California from climate and terrain-derived variables ». In : *Journal of Vegetation Science* 9.5, p. 733-748.
- FRANKLIN, S. E. et M. A. WULDER (2002). « Remote sensing methods in medium spatial resolution satellite data land cover classification of large areas ». In : *Progress in Physical Geography* 26.2, p. 173-205.
- FREUND, Y. et R. E. SCHAPIRE (1996). « Experiments with a new boosting algorithm ». In : *International Conference on Machine Learning (ICML)* volume 96, pages 148-156. ACM.
- FRIEDL, M. A. et al. (2010). « MODIS Collection 5 global land cover : Algorithm refinements and characterization of new datasets ». In : *Remote Sensing of Environment* 114.1, p. 168-182.
- FRITZ, S. et al. (2009). « Geo-Wiki.Org : The use of crowdsourcing to improve global land cover ». In : *Remote Sensing* 1.. P. 345-354.
- FRITZ, S. et al. (2012). « Geo-Wiki : An online platform for improving global land cover ». In : *Environmental Modelling Software* 31, p. 110-123.
- GAO, B.-C. (1996). « NDWI - a normalized difference water index for remote sensing of vegetation liquid water from space ». In : *Remote Sensing of Environment* 58.3, p. 257-266.
- GARNOT, V. S. F. et L. LANDRIEU (2021). « Panoptic Segmentation of Satellite Image Time Series with Convolutional Temporal Attention Networks ». In : *ICCV*.
- GAUILLAUME, H. (2015). « Masking "No-value" Pixels on GRD Products generated by the Sentinel-1 ESA IPF ». In : *ESA Tech. Rep, 2015. Reference MPC-0243, Issue 1.0*.
- GCOS (2016). « The global observing system for climate : Implementation needs. » In : *Global Climate Observing System Implementation Plan 2016*.
- GEBHARDT, S. et al. (2014). « Madmex : automatic wall-to-wall land cover monitoring for the mexican redd-mrv program using all landsat data ». In : *Remote Sensing* 6.5, p. 3923-3943.
- GEIST, H. J. et E. F. LAMBIN (2002). « Proximate causes and underlying driving forces of tropical deforestation ». In : *Bioscience* 52.2, p. 143-150.
- GENUER, R., J.-M. POGGI et C. TULEAU-MALOT (2010). « Variable selection using Random Forests ». In : *Pattern Recognition Letters* 31.14, p. 2225-2236.
- GEURTS, P., D. ERNST et L. WEHENKEL (2006). « Extremely randomized trees ». In : *Machine Learning* 63.1, p. 3-42.
- GHIMIRE, B. et al. (2012). « An evaluation of bagging, boosting, and Random Forests for land-cover classification in Cape Cod, Massachusetts, USA ». In : *GIS Science Remote Sensing* 49.5, p. 623-643.
- GIRI, C. P. (2012). « "Brief Overview of Remote Sensing of Land Cover." » In : *Remote Sensing of Land Use and Land Cover : Principles and Applications* vol. 8.2, p. 1. Boca Raton, FL : CRC Press.
- GIRRES, J. F. et G. TOUYA (2010). « Évaluation de la qualité du jeu de données français OpenStreetMap ». In : *Trans SIG*. 14.4, 435–459.
- GISLASON, P. O., J. A. BENEDIKTSSON et J. R. SVEINSSON (2006a). « Random Forests for land cover classification ». In : *Pattern Recognition Letters* 27.4, p. 294-300.
- (2006b). « Random Forests for land cover classification ». In : *Pattern Recognition* 27, 294–300.
- GOMEZ-CHOVA, L. et al. (2015). « Multimodal classification of remote sensing images : a review and future directions ». In : *Proceedings of the IEEE* 103.9, p. 1560-1584.

- GONG, P. et al. (2013). « Finer resolution observation and monitoring of global land cover : First mapping results with Landsat TM and ETM+ data ». In : *International Journal of Remote Sensing* 34.7, p. 2607-2654.
- GOODCHILD, M. F. et L. LI (2012). « Assurer la qualité des informations géographiques fournies volontairement ». In : *Statistique de naissance* 1, p. 110-20.
- GOPAL, S., C. E. WOODCOCK et A. H. STRAHLER (1999). « Fuzzy neural network classification of global land cover from a 1° AVHRR dataset ». In : *Remote Sensing of Environment* 67.2, p. 230-243.
- GRASER, A., M. STRAUB et M. DRAGASCHNIG (2015). « Osm est-il assez bon pour le routage des véhicules? une étude comparant les réseaux de rues à Vienne ». In : *Progress in Location-Based Services 2014. Cham : Springer* 2.2, p. 3-17.
- GREGORIO, A. Di et L. J. JANSEN (2000). « Land cover classification system (LCCS) : classification concepts and user manual for software version 1.0 ». In : *Food and Agriculture Organization of the United Nations*.
- GREKOUSIS, G., M. KAVOURAS et G. MOUNTRAKIS (2015). « "Land Cover Dynamics and Accounts for European Union 2011-2011." » In : *Third International Conference on Remote Sensing and Geoinformation (RSCy2015) Proceedings of SPIE, Vol. 9535, p. 953507*.
- GREKOUSIS, G. et G. MOUNTRAKIS (2015). « "Sustainable Development under Population Pressure : Lessons from Developed Land Consumption in the Conterminous US." » In : *PLoS ONE* 10.3, e0119675.
- GREKOUSIS, G., G. MOUNTRAKIS et M. KAVOURAS (2015). « An overview of 21 global and 43 regional land-cover mapping products ». In : *International Journal of Remote Sensing* 36.21, p. 5309-5335.
- GRESSIN, A. (2014). « Mise à jour d'une base de données d'occupation du sol à grande échelle en milieux naturels à partir d'une image satellite THR. PhD thesis, Université René Descartes-Paris V ».
- GRESSIN, A., C. MALLET et N. PAPANODITIS (2013). « Updating land cover databases using a single very high resolution satellite image ». In : *The ISPRS Workshop on Image Sequence Analysis* 2.3, p. 13-18.
- GRESSIN, A. et al. (2015). « Unsensored very high resolution land-cover mapping ». In : *Proc. of the IEEE International Geoscience and Remote Sensing Symposium, IGARSS*, pp. 2939-2942.
- GRÉGOIRE, J. M., K. TANSEY et J. M. N. SILVA (2003). « The GBA2000 initiative : Developing a global burned area database from SPOT-VEGETATION imagery ». In : *Int. J. Remote Sensing press* Vol. 24.
- GRÖCHENIG, S., R. BRUNAUER et K. REHRL (2014). « Estimation de l'exhaustivité des ensembles de données vgi en analysant l'activité de la communauté au fil du temps ». In : *Connecter une Europe numérique par le lieu et le lieu. Cham : Springer*, p. 3-18.
- GUO, L. (2011). « Margin framework for ensemble classifiers. Application to remote sensing data. Université de Bordeaux ».
- GÓMEZ, C., J. C. WHITE et M. A. WULDER (2016). « Optical remotely sensed time series data for land cover classification ». In : *ISPRS Journal of Photogrammetry and Remote Sensing* 116, p. 55-72.
- HACAR, M., B. KILIÇ et K. ŞAHBAZ (2015). « Analyse des données routières OpenStreetMap et caractérisation du comportement des contributeurs à Ankara, Turquie ». In : *ISPRS Int J Geo-Inf* 7.10, p. 400.
- HAEST, B. et al. (2010). « An object-based approach to quantity and quality assessment of heathland habitats in the framework of Natura 2000 using hyperspectral airborne AHS images ». In.
- HAGOLLE, O. et al. (2008). « Correction of aerosol effects on multi-temporal images acquired with constant viewing angles : Application to Formosat-2 images ». In : *Remote Sensing of Environment* 112.4, p. 1689-1701.

- HAGOLLE, O. et al. (2010). « A multi-temporal method for cloud detection, applied to FORMOSAT-2, VENUS, LANDSAT and SENTINEL-2 images ». In : *Remote Sensing of Environment* 114.8, p. 1747-1755.
- (2015a). « A multi-temporal and multi-spectral method to estimate aerosol optical thickness over land, for the atmospheric correction of FormoSat-2, LandSat, VENUS and Sentinel-2 images ». In : *Remote Sensing* 7.3, p. 2668.
- HAKLAY, M. (2010). « Quelle est la qualité de l'information géographique volontaire? Une étude comparative des ensembles de données OpenStreetMap et Ordnance Survey ». In : *Environ Plan B : Plan Des* 37.4, p. 682-703.
- HAN, D. C. et Y. YANG (2008). « A modified evidence combination approach based on ambiguity measure ». In : *2008 11th International Conference on Information Fusion*, p. 1-6.
- HANSEN, M. C. (Taylor & Francis, 2012). « Classification trees and mixed pixel training data ». In : *Remote Sensing of Land Use and Land Cover : Principles and applications* 95.
- HANSEN, M. C. et al. (2000). « Global land cover classification at 1 km spatial resolution using a classification tree approach ». In : *International Journal of Remote Sensing* 21.6-7, p. 1331-1364.
- HARALICK, R. M. (1979). « Statistical and structural approaches to texture ». In : *Proceedings of the IEEE* 67.5, p. 786-804.
- HECHT, R., C. KUNZE et S. HAHMANN (2013). « Mesure de l'exhaustivité des empreintes de construction dans OpenStreetMap dans l'espace et dans le temps ». In : *ISPRS Int J Geo-Inf* 2.4, 1066–1091.
- HEROLD, M. et al. (2008). « "Some Challenges in Global Land Cover Mapping : An Assessment of Agreement and Accuracy in Existing 1 km Datasets." » In : *Remote Sensing of Environment* 112, 2538–2556.
- HERVIEU, A., A. LE-BRIS et C. MALLET (2016). « Fusion of hyperspectral and vhr multispectral image classifications in urban areas ». In : *ISPRS Annals of Photogrammetry, Remote Sensing and Spatial Information Sciences* III-3, 457–464.
- HO, T. K. (1998). « The random subspace method for constructing decision forests ». In : *IEEE Transactions on Pattern Analysis and Machine Intelligence* 20.8, p. 832-844.
- HOMER, C. et al. (2007). « Completion of the 2001 national land cover database for the counterminous United States ». In : *Photogramm. Eng. Remote Sens.* 73, p. 337.
- HOSONUMA, N. et al. (2012). « An assessment of deforestation and forest degradation drivers in developing countries ». In : *Environmental Research Letter* 044009.7.
- HOUGHTON, R. A. et al. (2012). « Carbon emissions from land use and land-cover change ». In : *Biogeosciences* 9.12, p. 5125-5142.
- HUANG, C., L. S. DAVIS et J. R. G. TOWNSHEND (2002a). « An assessment of Support Vector Machines for land cover classification ». In : *International Journal of Remote Sensing* 23.4, p. 725-749.
- HUANG, C. et al. (2002b). « Derivation of a tasselled cap transformation based on Landsat 7 at-satellite reflectance ». In : *International Journal of Remote Sensing* 23.8, p. 1741-1748.
- HUANG, X. et L. ZHANG (2013). « An SVM ensemble approach combining spectral, structural, and semantic features for the classification of high-resolution remotely sensed imagery ». In : *IEEE Transactions on Geoscience and Remote Sensing* 51.1, p. 257-272.
- HUBERT-MOY, L. et al. (2001). « A comparison of parametric classification procedures of remotely sensed data applied on different landscape units ». In : *Remote Sensing of Environment* 75.2, p. 174-187.
- HUGHES, G. (1968). « On the mean accuracy of statistical pattern recognizers ». In : *IEEE Transactions on Information Theory* 14.1, p. 55-63.

- HÉGARAT-MASCLE, S. Le et R. SELTZ (2004). « Automatic change detection by evidential fusion of change indices ». In : *Remote Sensing of Environment* 91.3, 390–404.
- HÉGARAT-MASCLE, S. Le et al. (2006). « Performance of change detection using remotely sensed data and evidential fusion : comparison of three cases of application ». In : *International Journal of Remote Sensing* 27.16, 3515–3532.
- IENCO, D. et al. (September 2019). « Combining Sentinel-1 and Sentinel-2 Satellite Image Time Series for land cover mapping via a multi-source deep learning architecture ». In : *ISPRS Journal of Photogrammetry and Remote Sensing* 158.1, p. 11-22.
- INGLADA, J. (2016a). « OTB Gapfilling, a Temporal Gapfilling for Image Time Series Library ». In : <http://tully.ups-tlse.fr/jordi/temporalgapfilling>.
- (2016b). « PhenOTB, Phenological analysis for image time series ». In : <https://zenodo.org/record/45573>.
- INGLADA, J. et al. (2015a). « Assessment of an Operational System for Crop Type Map Production Using High Temporal and Spatial Resolution Satellite Optical Imagery ». In : *Remote sensing* 7, p. 12356-12379.
- INGLADA, J. et al. (2015b). « Assessment of an operationnal system for crop type map production using high temporal and spatial resolution satellite optical imagery ». In : *Remote Sensing* 7.9, p. 12356-12379.
- INGLADA, J. et al. (2017a). « Operational high resolution land cover map production at the country scale using satellite image time series ». In : *Remote Sensing* 9.1, p. 95.
- (2017b). « Operational High Resolution Land Cover Map Production at the Country Scale Using Satellite Image Time Series ». In : *Remote sensing* 9, p. 95.
- IPCC (2014). « Intergovernmental panel on climate change. » In : *Climate Change*.
- JACKSON, S. P. et al. (2013). « Évaluation de l'exhaustivité et de l'erreur spatiale des caractéristiques dans les informations géographiques fournies volontairement ». In : *ISPRS Int J Geo-Inf* 2.2, 507–530.
- JARNAGIN, S. T. (2004). « “Regional and Global Patterns of Population, Land Use, and Land Cover Change : An Overview of Stressors and Impacts.” » In : *GIScience Remote Sensing* 41.3, 207–227.
- JEON, B. (1999). « Decision fusion approach for multitemporal classification ». In : *IEEE Transactions on Geoscience and Remote Sensing* 37.3, 1227–1233.
- JIA, K. et al. (2014b). « Land cover classification of Landsat data with phenological features extracted from time series MODIS NDVI data ». In : *Remote Sensing* 6.11, p. 11518-11532.
- JIN, S. et al. (2013). « A comprehensive change detection method for updating the national land cover database to circa 2011 ». In : *Remote Sens. Environ.* 132, 159–175. URL : [doi:10.1016/j.rse.2006.01.020](https://doi.org/10.1016/j.rse.2006.01.020).
- JOHNSON, B. A. et K. IIZUKA (2016). « Integrating OpenStreetMap crowdsourced data and landsat time-series imagery for rapid land use / land cover (LULC) mapping : Case study of the Laguna de Bay area of the Philippines ». In : *Applied Geography* 67, p. 140-149.
- JOKAR, J. A. et al. (2015a). « L'émergence et l'évolution d'OpenStreetMap : une approche d'automates cellulaires ». In : *Int J Chiffre Terre* 8.1, 76–90.
- JOKAR, J. A. et al. (2015b). « OpenStreetMap dans GIScience ». In : *Cham : Springer*, p. 1-15.
- JOKAR, J. A. et al. (2015c). « Évaluation de la qualité des informations sur l'utilisation des terres fournies par openstreetmap par rapport aux ensembles de données faisant autorité ». In : *OpenStreetMap dans GIScience. Cham : Springer*, p. 37–58.
- JUNG, M. et al. (2006). « “Exploiting Synergies of Global Land Cover Products for Carbon Cycle Modeling.” » In : *Remote Sensing of Environment* 101.4, 534–553.

- JÖNSSON, P. et L. EKLUNDH (2002). « Seasonality extraction by function fitting to time-series of satellite sensor data ». In : *IEEE Transactions on Geoscience and Remote Sensing* 40.8, p. 1824-1832.
- KAMGA, A. et al. (2013). « Environmental impacts from overuse of chemical fertilizers and pesticides amongst market gardening in Bamenda, Cameroon ». In : *Revue Scientifique et Technique Forêt et Environnement du Bassin du Congo* 1, p. 6-19.
- KAPP, M. N., R. SABOURIN et P. MAUPIN (2007). « An empirical study on diversity measures and margin theory for ensembles of classifiers ». In : *0th International Conference on Information Fusion*, pages 1-8. IEEE.
- KAUTH, R. J. et G. S. THOMAS (1976). « The tasselled cap - a graphic description of the spectral-temporal development of agricultural crops as seen by landsat ». In : *LARS Symposia*, page 159.
- KESSLER, C. et R. T. De GROOT (2013). « La confiance comme mesure indirecte de la qualité de l'information géographique fournie volontairement dans le cas d'openstreetmap ». In : *La science de l'information géographique au coeur de l'Europe*. Cham : Springer, p. 21-37.
- KHATAMI, R., G. MOUNTRAKIS et S. V. STEHMAN (2016). « A meta-analysis of remote sensing research on supervised pixel-based land-cover image classification processes ». In : *Remote Sensing of Environment* 177, p. 89-100.
- KHOSHGOFTAAR, T. M., M. GOLAWALA et J. Van HULSE (2007). « An empirical study of learning from imbalanced data using Random Forests ». In : *IEEE International Conference on Tools with Artificial Intelligence 2007 (ICTAI) volume 2*, pages 310-317.
- KISSINGER, G. M., V. HEROLD et V. De SY (2012). « Drivers of Deforestation and Forest Degradation : A Synthesis Report for REDD+ Policymakers ». In : *Lexeme Consulting, Vancouver Canada*, p. 46.
- KNAUER, U. et U. SEIFFERT (2013). « A comparison of late fusion methods for object detection ». In : *Proc. of IEEE International Conference on Image Processing, ICIP*, pp. 3297-3301.
- KOLMOGOROV, V. et R. ZABIH (2004). « What energy functions can be minimized via graph cuts ? » In : *IEEE Transactions on Pattern Analysis and Machine Intelligence* 26.2, 65-81.
- KUNCHEVA, L. I. et C. J. WHITAKER (2003). « Measures of diversity in classifier ensembles and their relationship with the ensemble accuracy ». In : *Machine Learning* 51.2, p. 181-207.
- KUSHWAHA, S. et S. MUKHOPADHYAY (2010). « Sustainable development planning in Pathri Rao subwatershed using geospatial techniques ». In : *Current Science (00113891)*, p. 1479-1486.
- KUSSUL, N. et al. (2017). « Deep learning classification of land cover and crop types using remote sensing data ». In : *IEEE Geoscience and Remote Sensing Letters* 14.5, p. 778-782.
- KÖHLIN, G. et al. (2012). « What are the Linkages? Where is the Evidence? » In : *Energy, Gender and Development*.
- LABATUT, V. et H. CHERIFI (2012). « Accuracy measures for the comparison of classifiers ». In : *arXiv preprint arXiv : 1207.3790*.
- LAMBIN, E. F. et H. J. GEIST (2010). « Land-Use and Land-Cover Change. Local processes and Global Impacts ». In : *The IGBP Series*. Berlin : Springer-Verlag 151.2, 222 pp.
- LANDIS, J. R. et G. G. KOCH (1977). « The measurement of observer agreement for categorical data ». In : *Biometrics* 1, p. 159-174.
- LASSALLE, P. et al. (2015). « A scalable tile-based framework for region-merging segmentation ». In : *IEEE Transactions on Geoscience and Remote Sensing* 53.10, p. 5473-5485.
- LE-BRIS, A. et D. BOLDO (2008). « Extraction of land cover themes from aerial ortho-images in mountainous areas using external information ». In : *Photogrammetric Record* 23.124, 387-404.
- LE-BRIS, A. et N. CHEHATA (2011). « Change detection in a topographic building database using submetric satellite images ». In : *The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences* 38.3/W22, 25-30.

- LE-BRIS, A. et al. (2019). « Decision fusion of remote-sensing data for land cover classification (chap. 11) ». In : *Multimodal Scene Understanding, Elsevier*, pp. 341–382.
- LEE, H. et al. (2016). « Dynamic belief fusion for object detection ». In : *Proc. of the 2016 IEEE Winter Conference on Applications of Computer Vision, WACV*.
- LEFEBVRE, A., C. SANNIER et T. CORPETTI (2016). « Monitoring urban areas with Sentinel-2A data : application to the update of the Copernicus high resolution layer imperviousness degree ». In : *Remote Sensing* 8.7, p. 606.
- LI, C. et al. (2014). « Comparison of classification algorithms and training sample sizes in urban land classification with landsat thematic mapper imagery ». In : *Remote Sensing* 6.2, p. 964-983.
- LIAO, W., J. CHANUSSOT et W. PHILIPS (2018). « Remote sensing data fusion : guided filter-based hyperspectral pansharpening and graph-based feature-level fusion ». In : *Springer International Publishing*, pp. 243-275.
- LIU, C., P. FRAZIER et L. KUMAR (2007). « Comparative assessment of the measures of thematic classification accuracy ». In : *Remote Sensing of Environment* 107.4, p. 606-616.
- LONCAN, L. et al. (2015). « Hyperspectral pansharpening : a review ». In : *IEEE Geoscience and Remote Sensing Magazine* 3.3, p. 27-46.
- LOVELAND, T. R. et al. (2000). « Development of a global land cover characteristics database and IGBP DISCover from 1 km AVHRR data ». In : *International Journal of Remote Sensing* 21.6-7, p. 1303-1330.
- LOVELAND, T. R. et al. (2009). « ISLSCP II IGBP DISCover and SiB Land Cover, 1992-1993, 2009 ». In : *Hall, Forrest G., G. Collatz, B. Meeson, S. Los, E. Brown de Colstoun, and D. Landis (eds.). ISLSCP Initiative II Collection. Dataset Available on-line. URL : daac.ornl.gov.*
- LOWE, D. (2004). « Distinctive image features from scale-invariant keypoints ». In : *International Journal of Computer Vision* 2.60, 91–110.
- LUCAS, L. et al. (2007a). « Rule-based classification of multi-temporal satellite imagery for habitat and agricultural land cover mapping ». In : *ISPRS Journal of Photogrammetry and Remote Sensing* 62.3, p. 165-185.
- LUCAS, R. et al. (2007b). « Rule-based classification of multitemporal satellite imagery for habitat and agricultural land cover mapping ». In : *ISPRS Journal of Photogrammetry and Remote Sensing* 62, 165–185.
- LUCAS, R. et al. (2011). « Updating the Phase 1 habitat map of Wales, UK, using satellite sensor data. ISPRS Journal of Photogrammetry and Remote Sensing ». In : *ISPRS Journal of Photogrammetry and Remote Sensing* 66, 81–102.
- LV, Z. et al. (2017). « Morphological profiles based on differently shaped structuring elements for classification of images with very high spatial resolution ». In : *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing* 7.12, p. 4644-4652.
- MAGGIORI, E. et al. (2017). « Convolutional Neural Networks for large-scale remote-sensing image classification ». In : *IEEE Transactions on Geoscience and Remote Sensing* 55.2, p. 645-657.
- MAIRE, E. et al. (2012). « Télédétection de la trame verte arborée en haute résolution par morphologie mathématique ». In : *Revue Internationale de Géomatique* 22.4, p. 519-538.
- MAITRE, H. (2001). « Traitement des images de RSO ». In : *Edition Hermès Science Europe* 7, 41p-51p. URL : ISBN2-7462-0155-0.
- MANGOLINI, M. (1994). « Apport de la fusion d'images satellitaires multicapteurs au niveau pixels en télédétection et photo-interprétation Thèse de Doctorat en sciences, Université de Nice Sophia Antipolis, Nice, France », 174 p.
- MANNING, C. D., P. RAGHAVAN et H. Schütze et AL. (2008). « Introduction to information retrieval ». In : *Cambridge University Press* volume 1.

- MARTIN, A. (2009). « *Modélisation et gestion du conflit dans la théorie des fonctions de croyance* Habilitation à Diriger des Recherches de l'Université de Bretagne Occidentale, France ».
- MARTIN, A. et C. OSSWALD (2007a). « Une nouvelle règle de combinaison répartissant le conflit - Applications en imagerie Sonar et classification de cibles Radar ». In : *Traitement du Signal* 24.2, p. 71-82.
- (2007b). « Une nouvelle règle de combinaison répartissant le conflit – applications en imagerie sonar et classification radar ». In : *Traitement du Signal* 24, 71–82.
- MAS, J. F. et J. J. FLORES (2007). « The application of Artificial Neural Networks to the analysis of remotely sensed data ». In : *International Journal of Remote Sensing* 29.3, p. 617-663.
- MASSE, A. (2013). « *Développement et automatisation de méthodes de classification à partir de séries temporelles d'images de télédétection : application aux changements d'occupation des sols et à l'estimation du bilan carbone*. PhD thesis, Université de Toulouse, Université Toulouse III-Paul Sabatier ».
- MASSONNET, D. et J. C. SOUYRIS (2008). « Imaging with Synthetic Aperture Radar ». In : *édité par EPFL*.
- MCFEETERS, S. K. (1996). « The use of the Normalized Difference Water Index (NDWI) in the delineation of open water features ». In : *International Journal of Remote Sensing* 17.7, p. 1425-1432.
- MELLOR, A. et S. BOUKIR (2017). « Exploring diversity in ensemble classification : Applications in large area land cover mapping ». In : *ISPRS Journal of Photogrammetry and Remote Sensing* 129, p. 151-161.
- MELLOR, A. et al. (2015). « Exploring issues of training data imbalance and mislabelling on random forest performance for large area land cover classification using the ensemble margin ». In : *ISPRS Journal of Photogrammetry and Remote Sensing* 105, p. 155-168.
- MENARDI, G. et N. TORELLI (2014). « Trainin and assessing classification rules with imbalanced data ». In : *Data Mining and Knowledge Discovery*, pages 1-31.
- MEYER, W. B. et B. TURNER (1994). « Changes in Land Use and Land Cover : A Global Perspective ». In : *Cambridge : Cambridge University Press*.
- MIAO, X. et al. (2012). « Applying tree-based ensemble algorithms to the classification of ecological zones using multi-temporal multi-source remote-sensing data ». In : *International Journal of Remote Sensing* 33.6, p. 1823-1849.
- MINGHINI, M., M. A. BROVELLI et F. FRASSINELLI (2018). In : *ISPRS - Int Arch Photogramm Remote Sens Spat Inf Sci XLII-4/W8 :147–54*.
- MINGHINI, M. et al. (2017). « Réponse cartographique collaborative aux catastrophes via OpenStreetMap : le cas du tremblement de terre italien de 2016 ». In : *GEAM - GeoEng Environ Min* 151.2, p. 21-6.
- MOHAMMAD-DJAFARI, A. (2003). « A bayesian approach for data and image fusion ». In : *AIP Conference Proceedings* 659, 386–408.
- MOONEY, P. et P. CORCORAN (2014). « Analyse des modèles d'interaction et de co-édition parmi les contributeurs d'OpenStreetMap : Analyse des modèles d'interaction et de co-édition parmi les contributeurs d'OpenStreetMap ». In : *Transactions dans le SIG* 18.5, 633–59.
- MOONEY, P. et M. MINGHINI (2017). « Un examen des données OpenStreetMap ». In : *Cartographie et capteur citoyen*. Londres : Ubiquity Press, p. 37-59.
- MORA, B. et al. (2014). « "Global Land Cover Mapping : Current Status and Future Trends." » In : *Land Use and Land Cover Mapping in Europe : Practices and Trends. Remote Sensing and Digital Image Processing, edited by I. Manakos and M. Braun, 11–27*. Dordrecht : Springer.
- MOUNTRAKIS, G., J. IM et C. OGOLE (2011). « Support Vector Machines in remote sensing : A review ». In : *ISPRS Journal of Photogrammetry and Remote Sensing* 66.3, p. 247-259.

- MRÓZ, M. et A. SOBIERAJ (2004). « Comparison of several vegetation indices calculated on the basis of a seasonal SPOT XS time series, and their suitability for land cover and agricultural crop identification ». In : *Technical Sciences* 7, p. 39-66.
- MURA, M. Dalla et al. (2010). « Morphological attribute profiles for the analysis of very high resolution images ». In : *IEEE Transactions on Geoscience and Remote Sensing* 48.10, p. 3747-3762.
- MURTHY, K. V. S. (1998). « Automatic construction of decision trees from data : A multi-disciplinary survey ». In : *Data Mining and Knowledge Discovery* 2.4, p. 345-389.
- MUTTAQIEN, B. I., F. O. OSTERMANN et R. L. LEMMENS (2013). « Crédibilité des fonctionnalités d'OpenStreetMap ». In : *Trans SIG*. 22.3, 823-41.
- MÜLLER, K.-R. et al. (2001). « An introduction to kernel-based learning algorithms ». In : *IEEE Transactions on Neural Networks* 12.2, p. 181.
- NAGENDRA, H. (1999). « Biodiversity assessment at multiple scales : Linking remotely sensed data with field information ». In : *Proceedings of the National Academy of Sciences* 96, 9154-9158.
- NASIRI, A. et al. (2018). « Améliorer la qualité des géodonnées fournies par les citoyens grâce à leurs contributions historiques : le cas du réseau routier dans OpenStreetMap ». In : *ISPRS Int J Geo-Inf* 7.7, p. 253.
- NEIS, P. et D. ZIELSTRA (2014). « Recent developments and future trends in volunteered geographic information research : The case of OpenStreetMap ». In : *Future Internet* 1, p. 76-106.
- NEIS, P. et al. (2011). « L'évolution du réseau routier des cartes participatives : OpenStreetMap en Allemagne 2007-2011 ». In : *Futur Int* 4.1, 1-21.
- NGWA, N. E. (1989). « Cameroon small farmers and agro-pastoral credit. Herder and Herder. New York ». In.
- NIEL, T. G. Van, T. R. MCVICAR et B. DATT (2005). « On the relationship between training sample size and data dimensionality : Monte Carlo analysis of broadband multi-temporal classification ». In : *Remote Sensing of Environment* 98.4, p. 468-480.
- OH, S. I. et H. B. KANG (2017). « Object detection and classification by decision-level fusion for intelligent vehicle systems ». In : *Sensors* 17.1, p. 207.
- OLMSTED, C. (1993). « Scientific SAR user's guide ». In : *Alaska SAR Facility, ASF-SD-003*, p. 57.
- OLSON, D. M. et al. (2001). « Terrestrial Ecoregions of the World : A New Map of Life on Earth ». In : *Bioscience*, p. 933-938.
- OSMAN, J., J. INGLADA et J.-F. DEJOUX (2015). « Assessment of a markov logic model of crop rotations for early crop mapping ». In : *Computers and Electronics in Agriculture* 113, p. 234-243.
- OUERGHEMMI, W. et al. (2017). « A two-step decision fusion strategy : application to hyperspectral and multispectral images for urban classification ». In : *The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences XLII-1-W1*, 167-174.
- PAGET, M., A. GRESSIN et C. MALLET (2015). « Multi-temporal optical VHR image fusion for land-cover mapping ». In : *IEEE International Geoscience and Remote Sensing Symposium 2015 (IGARSS)*, pages 1913-1916.
- PAISITKRIANGKRAI, S. et al. (2015). « Effective semantic pixel labelling with convolutional networks and conditional random fields ». In : *Proc. of the IEEE Conference on Computer Vision and Pattern Recognition Workshop, CVPR*, pp. 36-43.
- PAL, M. (2005). « Random Forest classifier for remote sensing classification ». In : *International Journal of Remote Sensing* 26.1, p. 217-222.
- PAL, N. R. et J. C. BEZDEK (1994). « Measuring fuzzy uncertainty ». In : *IEEE Transactions on Fuzzy Systems* 2.2, 107-118.

- PAPARODITIS, N., I. BAGHLI et C. THOM (2000). « Reconstruction de modèles numériques de surfaces en zone urbaine à partir de prises de vues aériennes numériques à fort recouvrement ». In : *Bulletin d'Information de l'IGN* 3.71, 27–33.
- PAQUERAULT, S. (1998). « Restitution du relief à partir d'images radar par radarclinométrie par radarclinométrie Thèse en Technologie et Science de l'Information, Telecom Paris ».
- PARK, J. W., A. KOROSOV et M. BABIKER (23-28 avril 2017). « Efficient thermal noise removal of Sentinel-1 image and its impacts on sea ice applications. » In : *the Proceedings of the EGU General Assembly Conference Abstracts, Vienna, Austria* 19, p. 12613.
- PELLETIER, C. (2017). « Cartographie de l'occupation des sols à partir de séries temporelles d'images satellitaires à hautes résolutions : Identification et traitement des données mal étiquetées. PhD thesis, Université Toulouse 3 Paul Sabatier (UT3 Paul Sabatier) ».
- PELLETIER, C., G. I. WEBB et F. PETITJEAN (2019). « Temporal Convolutional Neural Network for the Classification of Satellite Image Time Series ». In : *Remote Sensing* 11.5, p. 523.
- PELLETIER, C. et al. (2016). « Assessing the robustness of random forests to map land cover with high resolution satellite image time series over large areas ». In : *Remote Sens. Environ.* 187, 156–168.
- PENMAN, J. et al. (2003). « Good Practice Guidance for Land Use, Land-Use Change and Forestry ». In : *IPCC National Greenhouse Gas Inventories Programme. UNEP-WMO-IGES, Japan.*
- PIECZYNSKI, W. (1989). « Estimation of context in random fields ». In : *Journal of Applied Statistics* 16.2, pp. 283-289.
- PIELKE, R. A. (2005). « Land use and climate change ». In : *Science* 310.5754, p. 1625-1626.
- PIERROT-DESEILLIGNY, M. (2014). « Micmac documentation : MicMac, Apero, Pastis and Other Beverages in a Nutshell! » In : URL : <http://logiciels.ign.fr/?-Micmac,3->.
- PIERROT-DESEILLIGNY, M. et I. CLERY (2011a). « Apero, an open source bundle adjustment software for automatic calibration and orientation of set of images ». In : *The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences XXXVIII-5/W16*, 1–8.
- PIERROT-DESEILLIGNY, M. et N. PAPARODITIS (2006). « A multiresolution and optimization-based image matching approach : An application to surface reconstruction from SPOT5-HRS stereo imagery ». In : *The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, p. 36.
- PIPER, J. (1992). « Variability and bias in experimentally measured classifier error rates ». In : *Pattern Recognition Letters* 13.10, p. 685-692.
- PITTMAN, K. et al. (2010). « Estimating global cropland extent with multi-year modis data ». In : *Remote Sensing* 2.7, p. 1844-1863.
- POHL, C. et J. Van GENDEREN (1998). « Multi-sensor image fusion in remote sensing : concepts methods and applications ». In : *International Journal of Remote Sensing* 19.5, p. 823-854.
- PONTIUS, R. G. et M. MILLONES (2011). « Death to Kappa : birth of quantity disagreement and allocation disagreement for accuracy assessment ». In : *International Journal of Remote Sensing* 32.15, p. 4407-4429.
- POSTADJIAN, T. et al. (2017). « Investigating the potential of deep neural networks for large-scale classification of very high resolution satellite images ».
- POTGIETER, A. B. et al. (2007). « Estimating crop area using seasonal time series of Enhanced Vegetation Index from MODIS satellite imagery ». In : *Australian Journal of Agricultural Research* 58.4, p. 316-325.
- POULAIN, V. et al. (2011). « High-resolution optical and SAR image fusion for building database updating ». In : *IEEE Transactions on Geoscience and Remote Sensing* 49.8, 2900–2910.
- POWERS, D. M. W. (2010b). « Evaluation : From Precision, Recall and F-Factor to ROC, Informedness, Markedness Correlation ». In : *Journal of Machine Learning Technologies* 2, p. 37-63.

- QUINLAN, J. R. (1986). « Induction of decision trees ». In : *Machine Learning* 1.1, p. 81-106.
- (1993). In : *C4. 5 : Programs for Machine Learning* volume 1. Morgan Kaufmann.
- RADOUX, J. et al. (2014). « Automated training sample extraction for global land cover mapping ». In : *Remote Sensing* 6.5, p. 3965.
- RIJSBERGEN, C. J. Van (1979). « Information Retrieval ». In : *London : Butterworths*.
- ROBIN, S. R., L. K. RUSSELL et M. Nyawira et AL. (2000). « Land-Use and Land-Cover Dynamics in Response to Changes in Climatic, Biological and Socio-political Forces : The Case of Southwestern Ethiopia ». In : *Landscape Ecology* 15.4, 339–355.
- ROBNIK-SIKONJA, M. (2004). « Improving Random Forests ». In : *European Conference on Machine Learning (ECML)* volume 3201, pages 359-370.
- ROCCHINI, D. et al. (2010a). « Remotely sensed spectral heterogeneity as a proxy of species diversity : Recent advances and open challenges ». In : *Ecological Informatics* 5, 318–329.
- ROCCHINI, D. et al. (2010b). « Spectral variation versus species diversity at different spatial scales : a test in African highland savannas ». In : *Journal of Environmental Monitoring* 12, p. 825.
- RODES, I. Arnau (2016). « *Exploitation of high spatial, spectral and temporal resolution Earth observation imagery for large area land cover estimation*. PhD thesis, Université Toulouse 3 Paul Sabatier (UT3 Paul Sabatier) ».
- RODRIGUEZ-GALIANO, V. et al. (2012a). « An assessment of the effectiveness of a Random Forest classifier for land-cover classification ». In : *ISPRS J. Photogramm. Remote Sensing* 67, 93–104.
- RODRIGUEZ-GALIANO, V. F. et al. (2012b). « An assessment of the effectiveness of a Random Forest classifier for land-cover classification ». In : *ISPRS Journal of Photogrammetry and Remote Sensing* 67, p. 93-104.
- ROGAN, J., J. FRNAKLIN et D. A. ROBERTS (2002). « A comparison of methods for monitoring multi-temporal vegetation change using Thematic Mapper imagery ». In : *Remote Sensing of Environment* 80.1, p. 143-156.
- ROKACH, L. (2010). « Ensemble-based classifiers ». In : *Artificial Intelligence Review* 33.1, p. 1-39.
- (2016). « Decision forest : Twenty years of research ». In : *Information Fusion* 27, p. 111-125.
- ROUSE, J. W. et al. (1973). « Monitoring Vegetation Systems in the Great Plains with ERTS ». In : *Third ERTS Symposium, Washington, NASA*, pages 309-317.
- RUNDQUIST, C., C. DONALD et H. LUOHENG (December 1997). « Comparison of NIR/RED ratio and first derivative of reflectance in estimating algal-chlorophyll concentration : A case study in a turbid reservoir ». In : *Remote Sensing of Environment* Volume 62, Issue 3, pp 253-261.
- SABOGAL, C. (2014). « Identifying drivers of land use change In South America. Capacity building workshop on ecosystem conservation and restoration to support achievement of the Aichi Biodiversity Targets - Linhares, Brazil ». In : p. 24-28.
- SASIKALA, S., S. BHARATHIDASON et C. J. VENKATESWARAN (2015). « Improving classification accuracy based on random forest model through weighted sampling for noisy data with linear decision boundary ». In : *Indian Journal of Science and Technology* 8.S8, p. 614-619.
- SAYER, J. A., C. S. HARCOURT et N. M. COLLINS (1992). « The Conservation Atlas of Tropical Forests : Africa ». In : *London, Macmillan*.
- SCEPAN, J. (1999). « Thematic validation of high-resolution global land-cover data sets ». In : *Photogrammetric Engineering and Remote Sensing* 65.9, p. 1051-1060.
- SCHAPIRE, R. E. et al. (1998). « Boosting the margin : A new explanation for the effectiveness of voting methods ». In : *The Annals of Statistics* 26.5, p. 1651-1686.
- SCHISTAD, A. H. (1996b). « Texture fusion and classification based on flexible discriminante analysis ». In : *In Int. Conf. Pattern Recognition (ICPR), Vienna, Austria*, pp. 596-600.

- SCHISTAD, A. H. (1999). « Contextual Data Fusion Applied to Forest Map Revision ». In : *IEEE Transactions on Geoscience and Remote Sensing* 37.3, pp. 1234-1243.
- SCHISTAD, A. H., T. TAXT et A. K. JAIN (1996a). « A Markov random field model for classification of multisource satellite imagery ». In : *IEEE Transactions on Geoscience and Remote Sensing* vol. 34.no. 1, pp. 100-113.
- SCHÖLKOPF, B. et A. J. SMOLA (2002). « Learning with kernels : Support Vector Machines, regularization, optimization, and beyond ». In : *MIT Press*.
- SEE, L. et al. (2015). « Building a hybrid land cover map with crowdsourcing and geographically weighted regression ». In : *ISPRS Journal of Photogrammetry and Remote Sensing* 103, p. 48-56.
- SEHRA, S., J. SINGH et H. RAI (2017a). « Utilisation de l'analyse sémantique latente pour identifier les tendances de la recherche dans OpenStreetMap ». In : *ISPRS Int J Geo-Inf.* 6.7, p. 195.
- (2017b). « Évaluation des données OpenStreetMap à l'aide d'indicateurs de qualité intrinsèque : une extension de la boîte à outils de traitement QGIS ». In : *Internet du futur* 9.2, p. 15.
- SENF, C. et al. (2015). « Mapping land cover in complex Mediterranean landscapes using Landsat : Improved classification accuracies from integrating multi-seasonal and synthetic imagery ». In : *Remote Sensing of Environment* 156, p. 527-536.
- SHAFER, G. (1976). « A Mathematical Theory of Evidence ». In : *Princeton University Press*.
- SHEEREN, D. et al. (2012). « La télédétection pour la cartographie de la trame verte en milieu agricole ». In : *Revue internationale de Géomatique* 22.4, p. 539-563.
- SHIRIMA, D. D. et al. (2011). « Carbon storage, structure and composition of miombo woodlands in Tanzania's Eastern Arc Mountains ». In : *African Journal of Ecology* 49.3, 332-342.
- SILLEOS, N. G. et al. (2006). « Vegetation indices : advances made in biomass estimation and vegetation monitoring in the last 30 years ». In : *Goecarto International* 21.4, p. 21-28.
- SKIDMORE, A. K. et al. (2010). « Forage quality of savannas simultaneously mapping foliar protein and polyphenols for trees and grass using hyperspectral imagery ». In : *Remote Sensing of Environment* 114.1, 64-72.
- SMALL, D. et A. SCHUBERT (2008). « Guide to ASAR Geocoding ». In : *ESA-ESRIN Technical Note RSL-ASAR-GC-AD, University of Zurich : Zurich, Switzerland* Volume 1, p. 36.
- SMITH, M. R. et T. MARTINEZ (2015). « Using classifier diversity to handle label noise ». In : *IEEE International Joint Conference on Neural Networks 2015 (IJCNN)*, pages 1-8.
- SOFTWARE, SNAP (1 mai 2018). « Help Document 2019 ». In : *Available online : <https://step.esa.int/main/toolboxes/snap>*.
- SOLAIMAN, B., L. E. PIERCE et F. T. ULABY (1999). « Multisensor data fusion using fuzzy concepts : application to land-cover classification using ERS-1/JERS-1 SAR composites ». In : *IEEE Transactions on Geosciences and Remote Sensing* vol. 37.no. 3, pp. 1316-1326.
- STAPENHURST, R. J. (2012). « *Diversity, margins and non-stationary learning*. PhD thesis, University of Manchester ».
- STEHMAN, S. V. (1997). « Selecting and interpreting measures of thematic classification accuracy ». In : *Remote Sensing of Environment* 62.1, p. 87-102.
- STOCKER, O. et A. LE-BRIS (2020). « Can SPOT-6/7 CNN semantic segmentation improve Sentinel-2 based land cover products ? Sensor assessment and fusion ». In : *ISPRS Annals of the Photogrammetry, Remote Sensing and Spatial Information Sciences*.
- SUN, Y., A. K. C. WONG et M. S. KAMEL (2009). « Classification of imbalanced data : A review ». In : *International Journal of Pattern Recognition and Artificial Intelligence* 23.04, p. 687-719.

- SWART, R. E. (2016). « Monitoring 40 years of land use change in the Mau forest complex, Kenya : a land use change driver analysis. Thesis Report GIRS-2016-29 Centre for Geo-Information Science and Remote Sensing Wageningen ». In : 72.
- SY, V. De (2016). « Remote sensing of land use and carbon losses following tropical deforestation. PhD Thesis, University of Wageningen. » In.
- SY, V. De et M. HEROLD (2014). « Monitoring drivers for REDD+ : status and options ». In : *2nd GLP open Science Meeting, Berlin, Germany* 19.21.
- SY, V. De et al. (2015a). « Drivers of deforestation in REDD+ countries : Results from a pan-tropical remote sensing analysis ». In : *Our common Future Under Climate Change conference, Paris* 7.
- SY, V. De et al. (2015b). « Land use patterns and related carbon losses following deforestation in South America. Environmental Research Letters, IOP Publishing Ltd 10 ». In : 124004.
- TAGNE, H. et al. (2022). « Classification of Vegetation CLasses by Using Time Series of Sentinel-2 images for Large Scale Mapping in Cameroon ». In : *ISPRS Ann. Photogramm. Remote Sens. Spatial Inf. Sci.* V-3-2022, 673–680.
- TARDY, B. (December 2019). « Méthodes d'exploitation de données historiques pour la production de cartes d'occupation des sols à partir d'images de télédétection et en absence de données de référence de la période à cartographier Thèse de doctorat en Surfaces et interfaces continentales, Hydrologie, Université de Toulouse 3 ». In.
- TATEISHI, R. et al. (2014). « Production of global land cover data-GLCNMO2008 ». In : *Journal of Geography and Geology* 6.3, p. 99.
- TCHAWA, P. (2006). « Relief et hydrographie ». In : *Paris, Ed. JA. in Cameroun*, p. 58.
- TCHINDJANG, M. (2010). « Urbanization and Poverty ; Case study of Yaoundé. Guest Speaker, LUNA Project, Johannesburg ». In.
- (2012). « Paradoxes et Risques Dans les Hautes Terres Camerounaises : Multifonctionnalité Naturelle et Sous Valorisation Humaine ; Université de Paris : Paris, France ». In : p. 266.
- (2019). « L'urbanisation durable comme outil de mise en oeuvre de la transformation sociale et écologique (TSE) au Cameroun : quoi faire et comment ? « Médias et transformation sociale écologique (TSE) au Cameroun : Comment passer à l'action maintenant ? ». Friedrich Ebert Stiftung, Yaoundé. » In : *Scientific Data*.
- TCHINDJANG, M. et al. (2012). « Challenges of climate change, landscape dynamics and environmental risks in Cameroon ». In : *Landscape Evolution, Neotectonics and Quaternary Environmental Change in Southern Cameroon : Palaeoecology of Africa* 31, p. 237-286.
- TCHUENTE, A., J. ROUJEAN et S. JONG (2011). « "Comparison and Relative Quality Assessment of the GLC2000, GLOBCOVER, MODIS and ECOCLIMAP Land Cover Data Sets at the African Continental Scale." » In : *International Journal of Applied Earth Observation and Geoinformation* 13, 207–219.
- THOMAS, J., P.-E. JOUVE et N. NICOLOYANNIS (2006). « Optimisation and evaluation of Random Forests for imbalanced datasets ». In : *International Symposium on Methodologies for Intelligent Systems*, pages 622-631.
- TIAN, J. et J. DEZERT (2019). « Fusion of multispectral imagery and dsms for building change detection using belief functions and reliabilities ». In : *International Journal of Image and Data Fusion* 10.1, 1–27.
- TIAN, Y., Q. ZHOU et X. FU (2019). « Une analyse de l'évolution, de l'exhaustivité et des modèles spatiaux des données de construction OpenStreetMap en Chine ». In : *ISPRS Int J Geo-Inf* 8.1, p. 35.
- TRIAS-SANZ, R. (2006). « Texture orientation and period estimator for discriminating between forests, orchards, vineyards, and tilled fields ». In : *IEEE Transactions on Geoscience and Remote Sensing* 44.10, p. 2755-2760.

- TSALÉFAC, M. (2006). In : *Paris, Ed. JA. in Cameroun*, p. 62.
- TSENBABAZAR, N., S. BRUIN et M. HEROLD (2015). « "Assessing Global Land Cover Reference Datasets for Different User Communities." » In : *ISPRS Journal of Photogrammetry and Remote Sensing* 103, 93–114.
- TSYMBAL, A., M. PECHENIZKIY et P. CUNNINGHAM (2006). « Dynamic integration with Random Forests ». In : *European Conference on Machine Learning (ECML)*, pages 801-808. Springer.
- TU, Z. et X. BAI (2010). « Auto-context and its application to high-level vision tasks and 3D brain image segmentation ». In : *IEEE Transactions on Pattern Analysis and Machine Intelligence* 32.10, 1744–1757.
- TUCKER, C. J. (1979). « Red and photographic infrared linear combinations for monitoring vegetation ». In : *Remote Sensing of Environment* 8.2, p. 127-150.
- TUPIN, F., I. BLOCH et H. MAITRE (1999). « A first step toward automatic interpretation of SAR images using evidential fusion of several structure detectors ». In : *IEEE Transactions on Geoscience and Remote Sensing* 37.3, 1327–1343.
- TURNER, B. (L.II 2006). « "Land Change as a Forcing Function in Global Environmental Change." » In : *Our Earth's Changing Land : An Encyclopedia of Land-Use and Land-Cover Change* vol. 1 (A–K), edited by H. J. Geist, xxv–xxxii. Westport : Greenwood Press, p. 953507.
- TURNER, W. et al. (2003). « Remote sensing for biodiversity science and conservation ». In : *Trends in Ecology Evolution* 18, 306–314.
- UICN (1992). « L'Atlas pour la conservation des forêts tropicales d'Afrique ». In : *Ed Jean-Pierre de Monza*, p. 133.
- UNEP (2005). « Facing the Facts : Assessing the Vulnerability of Africa's Water Resources to Environmental Change ». In : *early warn Edition. Nairobi*.
- UNRUH, J., L. CLIGGET et R. HAY (2005). « Migrant Land Rights Reception and 'Clearing to Claim' in Sub-Saharan Africa : A Deforestation Example from Southern Zambia ». In : *Natural Resources Forum* 29.3, 190–198.
- VALERO, S. et al. (2016). « Production of a dynamic cropland mask by processing remote sensing image series at high temporal and spatial resolutions ». In : *Remote Sensing* 8.1, p. 55.
- VAN, W. et D. FRASER (1994). « A self-organizing map model for spatial and temporal contextual classification ». In : *In IEEE Symp. Geosci. Remote Sensing (IGARSS), Lincoln, NE*, pp. 529-531.
- (1999). « Multisource data fusion with multiple self organizing maps ». In : *IEEE Transactions on Geoscience and Remote Sensing* vol. 37.no. 3, pp. 1344-1349.
- VEREGIN, H. (1999). « Paramètres de qualité des données ». In : *Hoboken, New Jersey : John Wiley Sons*, p. 177-189.
- VIEIRA, M. A. et al. (2012). « Object based image analysis and data mining applied to a remotely sensed landsat time-series to map sugarcane over large areas ». In : *Remote Sensing of Environment* 123, p. 553-562.
- VINCENT, A., J. INGLADA et L. PEÑA (2022). « Sahel Land Cover OSO 2018 [Data set]. Zenodo. » In : URL : <https://doi.org/10.5281/zenodo.7373166>.
- WALD, L. (1998). « Data fusion : A conceptual approach for an efficient exploitation of remote sensing images ». In : *In Proc. 2nd Conf. Fusion of Earth Data : Merging Point Measurement. Raster Maps and Remotely Sensed Images*, pp. 17-23.
- (1999). « Some terms of reference in data fusion ». In : *IEEE Transactions on Geoscience and Remote Sensing* 37.3, p. 1190-1193.
- WALDNER, F., G. S. CANTO et P. DEFOURNY (2015a). « Automated annual cropland mapping using knowledge-based temporal features ». In : *ISPRS Journal of Photogrammetry and Remote Sensing* 110, p. 1-13.

- WALDNER, F. et al. (2015b). « Land cover and crop type classification along the season based on biophysical variables retrieved from multi-sensor high-resolution time series ». In : *Remote Sensing* 7.8, p. 10400-10424.
- WALL, R. S. et al. (2018a). « The State of African Cities 2018 : The geography of African investment. UN-Habitat IHS-Erasmus University Rotterdam ». In : *United Nations Human Settlements Programme (UN-Habitat)*, 158–167.
- (2018b). « The State of African Cities : The geography of African investment ». In : *United Nations Human Settlements Programme (UN-Habitat) 2*, p. 322.
- WANG, J. et al. (2015). « Mapping global land cover in 2001 and 2010 with spatial-temporal consistency at 250m resolution ». In : *ISPRS Journal of Photogrammetry and Remote Sensing* 103, p. 38-47.
- WASKE, B. et J. BENEDIKTSSON (2007a). « Fusion of support vector machines for classification of multisensor data ». In : *IEEE Transactions on Geoscience and Remote Sensing* 45, 3858–3866.
- WASKE, B. et J. A. BENEDIKTSSON (2007b). « Fusion of Support Vector Machines for classification of multisensor data ». In : *IEEE Transactions on Geoscience and Remote Sensing* 45.12, p. 3858-3866.
- WASKE, B. et S. van der LINDEN (2008). « Classifying multilevel imagery from SAR and optical sensors by decision fusion ». In : *IEEE Transactions on Geoscience and Remote Sensing* 46.5, p. 1457-1466.
- WASSEIGE, C. De et al. (2015). « État des Forêts 2015 - Forêts et changements climatiques ». In : p. 128.
- WATSON, R. T. et al. (2000). « Land use, Land-use Change, and Forestry : A Special Report ». In : *IPCC Cambridge University Press, Cambridge, UK.*, p. 375.
- WEGNER, J. D. et al. (2011). « Building detection from one orthophoto and high-resolution InSAR data using conditional random fields ». In : *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing* 4, 83–91.
- WEISS, G. M. et F. PROVOST (2015). « Learning when training data are costly : the effect of class distribution on tree induction ». In : *Journal of Artificial Intelligence Research* 19, p. 315-354.
- WENDL, C. et al. (2018). « Decision fusion of SPOT-6 and multitemporal Sentinel-2 images for urban area detection ». In : *Proc. of the IEEE International Geoscience and Remote Sensing Symposium, IGARSS*, pp. 1734–1737.
- WHITCRAFT, A. K., I. BECKER-RESHEF et C. O. JUSTICE (2015). « A framework for defining spatially explicit earth observation requirements for a global monitoring initiative (GEOGLAM) ». In : *Remote Sensing* 7.2, p. 1461-1481.
- WHITE, F. (1983). « Etude de la végétation de la Réserve de la Lopé ». In : *Projet ECOFAC, Rapport final, AGRECO C.T.F.T., Libreville.*
- XIA, J., Z. MING et A. IWASAKI (2018). « Multiple sources data fusion via deep forest ». In : *Proc. of the IEEE International Geoscience and Remote Sensing Symposium, IGARSS*, pp. 1722–1725.
- XIAO, X. et al. (2005). « Mapping paddy rice agriculture in southern china using multi-temporal MODIS images ». In : *Remote Sensing of Environment* 95.4, p. 480-492.
- XU, H. (2006). « Modification of normalised difference water index (NDWI) to enhance open water features in remotely sensed imagery ». In : *International Journal of Remote Sensing* 27.14, p. 3025-3033.
- YAN, W. Y., A. SHAKER et N. E. ASHMAWY (2015). « “Urban Land Cover Classification Using Airborne Lidar Data : A Review.” » In : *Remote Sensing of Environment* 158, 295–310.
- YANG, S., M. WANG et L. JIAO (2012). « Fusion of multispectral and panchromatic images based on support value transform and adaptive principal component ». In : *Information Fusion* 13.3, p. 177-184.
- YEOM, J., Y. HAN et Y. KIM (2013). « Separability analysis and classification of rice fields using KOMPSAT-2 high resolution satellite imagery ». In : *Research Journal of Chemistry and Environment* 17, p. 12.

- YOKOYA, N. et al. (2018). « Open data for global multimodal land use classification : outcome of the 2017 IEEE GRSS Data Fusion Contest ». In : *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing* 11.5, 1363–1377.
- YONG, D. et al. (2004). « Combining belief functions based on distance of evidence ». In : *Decision Support Systems* 38.3, p. 489-493.
- YU, L., J. WANG et P. GONG (2013b). « Improving 30 m global land-cover map FROM-GLC with time series MODIS and auxiliary data sets : a segmentation-based approach ». In : *International Journal of Remote Sensing* 34.16, p. 5851-5867.
- YU, L. et al. (2013a). « FROM-GLC : 30 m global cropland extent derived through multisource data integration ». In : *International Journal of Digital Earth* 6.6, p. 521-533.
- YU, L. et al. (2014). « A multi-resolution global land cover dataset through multisource data aggregation ». In : *Sci. China Earth Sci.* 57, 2317–2329.
- YU, L. et al. (2014a). « Meta-discoveries from a synthesis of satellite-based land-cover mapping research ». In : *International Journal of Remote Sensing* 35.13, p. 4573-4588.
- YUAN, Y., X. ZHENG et X. LU (2017). « Hyperspectral image superresolution by transfer learning ». In : *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing* 10.5, p. 1963-1974.
- ZADEH, L. (1965). « Fuzzy sets ». In : *Information and Control* 8.3, 338–353.
- ZANAGA, D. et al. (2021). « ESA WorldCover 10 m 2020 ». In : v100. URL : <https://doi.org/10.5281/zenodo.5571936>.
- ZHA, Y., J. GAO et S. NI (2003). « Use of normalized difference built-up index in automatically mapping urban areas from TM imagery ». In : *International Journal of Remote Sensing* 24.3, p. 583-594.
- ZHANG, X. et al. (2003). « Monitoring vegetation phenology using MODIS ». In : *Remote Sensing of Environment* 84.3, p. 471-475.
- ZHANG, Z. et al. (2014). « A 2010 update of national land use/cover database of China at 1 :100000 scale using medium spatial resolution satellite images ». In : *Remote Sens. Environ.* 149, 142–154.
- ZHAO, P. et al. (2015). « Analyse statistique sur l'évolution des réseaux routiers OpenStreetMap à Pékin ». In : *Physique A : Stat Mech Appl.* 420, 59–72.
- ZHU, X. X. et al. (2017). « Deep learning in remote sensing : a comprehensive review and list of resources ». In : *IEEE Geoscience and Remote Sensing Magazine* 5.4, p. 8-36.

Annexes

Données satellitaires et de référence

Sommaire

A.1	Dates des images satellitaires utilisées	331
A.2	Niveau de traitements des données satellitaires	334
A.3	Découpage	334
A.4	Nomenclature	334
	A.4.1 <i>Land Cover Classification System</i>	334
	A.4.2 <i>Base de données de l'INC</i>	342
	A.4.3 <i>Légende</i>	342

A.1 Dates des images satellitaires utilisées

Les dates d'acquisition disponibles pour la série temporelle composée d'images Sentinel-1 (polarisations *VH* et *VV*) représentées par les deux emprises (*en bleu*) et (*en rose*) et d'images Sentinel-2 représentées par l'emprise (*en rouge*) dans la Figure 3.16 de l'année complète 2018 sur la première zone d'intérêt représentée par la tuile *T33PUL* dans la Figure 3.5 sont indiquées dans les Tableaux A.1, A.2 et A.3.

Les dates d'acquisition disponibles pour la série temporelle composée d'images Sentinel-1 (polarisations *VH* et *VV*) représentées par l'emprise (*en bleu*) et d'images Sentinel-2 représentées par l'emprise (*en rouge*) dans la Figure 3.17 de l'année complète 2018 sur la deuxième zone d'intérêt représentée par la tuile *T32NPL* dans la Figure 3.8 sont indiquées dans les Tableaux A.4 et A.5.

Les dates d'acquisition disponibles pour la série temporelle composée d'images Sentinel-2 de l'année complète 2018 pour les cinq tuiles restantes dont les dispositions sont visibles dans la Figure 3.4 en suivant la nomenclature de l'ESA sur la première zone d'étude (*ZONE1*), sont indiquées dans le Tableau A.6.

Les dates d'acquisition disponibles pour la série temporelle composée d'images Sentinel-2 de l'année complète 2018 pour les onze tuiles restantes dont les dispositions sont visibles dans la Figure 3.7 en suivant la nomenclature de l'ESA sur la deuxième zone d'étude, sont indiquées dans les Tableaux (A.7 et A.8) pour les six premières et les Tableaux (A.9 et A.10) pour les cinq tuiles restantes.

TAB. A.1 – Images Sentinel-1 et Sentinel-2 de l'année 2018 disponibles sur la zone d'intérêt T33PUL.

	Sentinel-1A/-1B	Sentinel-2A/-2B
Dates	04/01	04/01
	05/01	07/01
	16/01	09/01
	17/01	12/01
	28/01	14/01
	29/01	17/01
	09/02	19/01
	10/02	22/01
	21/02	24/01
	22/02	27/01
	05/03	29/01
	06/03	01/02
	17/03	06/02
	18/03	08/02
	29/03	11/02
	30/03	18/02
	10/04	21/02
	11/04	23/02
	22/04	26/02
	04/05	03/03
	05/05	05/03
	16/05	08/03
	17/05	10/03
	28/05	13/03
	29/05	15/03
	09/06	18/03
	10/06	20/03
	21/06	25/03
	22/06	28/03
	03/07	30/03
	04/07	04/04
	15/07	07/04
	16/07	09/04
	27/07	12/04
	08/08	14/04

TAB. A.2 – Suite du Tableau A.1.

	Sentinel-1A/-1B	Sentinel-2A/-2B
	09/08	17/04
	20/08	19/04
	01/09	22/04
	02/09	24/04
	13/09	27/04
	14/09	29/04
	25/09	04/05
	26/09	07/05
	07/10	17/05
	08/10	19/05
	19/10	24/05
	20/10	03/06
	01/11	08/06
	12/11	13/06
	13/11	18/06
	24/11	26/06
	25/11	28/06
	06/12	01/07
	07/12	06/07
	18/12	08/07
	19/12	13/07
	30/12	18/07
	31/12	21/07
	31/12	23/07
	31/12	28/07
	31/12	02/08
	31/12	07/08
	31/12	10/08
	31/12	12/08
	31/12	15/08
	31/12	01/09
	31/12	04/09
	31/12	09/09
	31/12	09/09
	31/12	11/09

TAB. A.3 – Suite et
fin
du Tableau A.1.

	Sentinel-1A/-1B	Sentinel-2A/-2B
Dates	31/12	16/09
	31/12	19/09
	31/12	26/09
	31/12	29/09
	31/12	01/10
	31/12	04/10
	31/12	09/10
	31/12	11/10
	31/12	14/10
	31/12	16/10
	31/12	19/10
	31/12	21/10
	31/12	26/10
	31/12	29/10
	31/12	31/10
	31/12	03/11
	31/12	05/11
	31/12	08/11
	31/12	10/11
	31/12	13/11
	31/12	15/11
	31/12	18/11
	31/12	20/11
	31/12	23/11
	31/12	28/11
	31/12	05/12
	31/12	08/12
	31/12	10/12
	31/12	13/12
	31/12	15/12
	31/12	18/12
	31/12	20/12
	31/12	23/12
	31/12	25/12
	31/12	28/12

TAB. A.4 – Images Sentinel-1 et Sentinel-2 de
l'année 2018 disponibles sur la zone d'intérêt
T32NPL.

	Sentinel-1A/-1B	Sentinel-2A/-2B
	09/01	07/01
	21/01	12/01
	02/02	17/01
	14/02	22/01
	26/02	27/01
	10/03	01/02
	22/03	06/02
	03/04	11/02
	15/04	16/02
	27/04	21/02
	09/05	03/03
	21/05	13/03
	14/06	18/03
	26/06	28/03
	08/07	17/04
	20/07	22/04
	01/08	02/05
	25/08	07/05
	06/09	22/05
	18/09	27/05
	30/09	11/06
	12/10	16/06
	24/10	21/06
	05/11	26/06
	17/11	01/07
	29/11	11/07
	11/12	31/07
	23/12	05/08
		10/08
		15/08
		20/08
		30/08
		04/09
		14/09
		19/09

TAB. A.5 – Suite et fin du Tableau A.4.

	Sentinel-1A/-1B	Sentinel-2A/-2B
Dates		29/09
		09/10
		19/10
		24/10
		03/11
		08/11
		18/11
		23/11
		28/11
		13/12
		18/12
		23/12

A.2 Niveau de traitements des données satellitaires

Concernant les images Sentinel-2, les produits fournis par le pôle Theia à travers l'atelier de production Multi-Satellite, multi-Capteurs pour des données multi-Temporelles (MUSCATE) sont les suivants :

A.3 Découpage

La Figure A.1 montre les découpages utilisés pour les images Sentinel-2. Les images Sentinel-2 sont fournies en projection *Universal Transverse Mercator (UTM)* (32 et 33).

A.4 Nomenclature

A.4.1 Land Cover Classification System

Le système *LCCS* s'appuyant sur le langage *LCML* est considéré comme l'un des standards pour la classification. Chaque classe d'OCS est définie par la combinaison d'un ensemble d'attributs indépendants. *LCCS* permet de décrire l'ensemble des classes d'OCS quelque soit la zone géographique étudiée.

La définition de la nomenclature *LCCS* repose sur deux étapes : (1) une étape dichotomique, et (2) une étape modulaire hiérarchique. La Figure A.2 montre l'ensemble de la nomenclature ainsi formée.

La première étape dichotomique décrit huit classes d'OCS en niveaux hiérarchiques en se basant sur la présence de végétation ou non, le type de milieu et le degré d'artificialisation. Contrairement à d'autres nomenclatures hiérarchiques, celle du *LCCS* permet de classer toute la surface terrestre sans aucun conflit : chaque point du globe n'appartient qu'à une seule catégorie.

La deuxième étape modulaire hiérarchique permet d'obtenir une nomenclature plus fine que celle du troisième niveau. Elle repose sur l'utilisation de trois attributs qui sont spécifiques à chacune des huit classes. Ces attributs concernent l'OCS (*en bleu* dans la Figure A.2), l'environnement (*en magenta* dans la Figure A.2), et des aspects techniques spécifiques (*en vert* dans la Figure A.2).

TAB. A.6 – Images disponibles pour la série temporelle composée d’images Sentinel-2A/-2B de l’année 2018 acquises pour les cinq tuiles restantes sur la première zone d’étude (ZONE1) (nomenclature ESA).

	<i>T33PTK</i>	<i>T33PTL</i>	<i>T33PTM</i>	<i>T33PUK</i>	<i>T33PUM</i>
Dates	03/12	03/12	30/11	30/11	30/11
	03/12	03/12	03/12	03/12	03/12
	23/12	23/12	23/12	23/12	23/12
	26/12	26/12	30/12	30/12	30/12
	05/01	02/01	12/01	12/01	12/01
	12/01	04/02	19/01	08/02	12/03
	25/01	15/03	12/03	22/03	22/03
	04/02	22/03	22/03	11/04	29/03
	14/02	01/04	29/03	14/04	08/04
	12/03	11/04	01/04	18/04	11/04
	15/03	14/04	08/04	28/04	18/04
	22/03	01/05	11/04	01/05	28/04
	01/04	04/05	18/04	04/05	01/05
	11/04	21/05	28/04	18/05	18/05
	14/04	24/05	01/05	21/05	21/05
	24/04	20/06	18/05	28/05	28/05
	01/05	23/06	21/05	20/06	07/06
	04/05	03/07	28/05	23/06	10/06
	14/05	10/07	07/06	27/06	20/06
	21/05	23/07	20/06	07/07	27/06
	24/05	30/07	27/06	10/07	07/07
	20/06	02/08	07/07	17/07	10/07
	23/06	12/08	10/07	27/07	17/07
	03/07	19/08	17/07	30/07	20/07
	10/07	22/08	20/07	06/08	27/07
	13/07	01/09	27/07	12/08	30/07
	23/07	11/09	30/07	16/08	06/08
	30/07	21/09	06/08	22/08	16/08
	02/08	28/09	16/08	26/08	19/08
	12/08	11/10	19/08	01/09	26/08
	19/08	19/08	26/08	05/09	29/08
	22/08	22/08	05/09	11/09	05/09
	01/09	01/09	08/09	15/09	08/09
	08/09	08/09	08/09	15/09	28/09
	11/09	11/09	18/09	15/10	15/10
	18/09	18/09	28/09	18/09	18/09
	21/09	21/09	08/10	08/10	05/10
	28/09	28/09	15/10	15/10	08/10
	01/10	01/10	01/10	01/10	15/10
	08/10	08/10	08/10	08/10	08/10

TAB. A.7 – Images disponibles pour la série temporelle composée d’images Sentinel-2A/-2B de l’année 2018 acquises pour les six premières tuiles restantes sur la deuxième zone d’étude (ZONE2) (nomenclature ESA).

	<i>T32NMK</i>	<i>T32NML</i>	<i>T32NMM</i>	<i>T32NNK</i>	<i>T32NNL</i>	<i>T32NNM</i>
Dates	05/01	19/07	05/01	05/01	04/02	19/06
	10/01	08/08	10/01	07/01	06/02	03/08
	15/01	13/08	15/01	10/01	19/02	10/08
	25/01	28/08	20/01	15/01	21/02	13/08
	30/01	12/09	25/01	17/01	24/02	15/08
	04/02	27/09	30/01	20/01	03/03	28/08
	24/02	02/10	04/02	22/01	06/03	04/09
	06/03	22/10	19/02	25/01	13/03	12/09
	21/03	27/10	16/03	27/01	16/03	14/09
	31/03	11/11	21/03	30/01	18/03	19/09
	20/04	16/11	26/03	01/02	26/03	22/09
	30/04	21/11	31/03	04/02	31/03	27/09
	15/05	06/12	05/04	06/02	05/04	29/09
	30/05	16/12	20/04	19/02	17/04	07/10
	09/06	21/12	30/04	21/02	22/04	09/10
	24/06	26/12	15/05	24/02	30/04	19/10
	29/06	31/12	30/05	03/03	02/05	27/10
	09/07		14/06	06/03	07/05	29/10
	14/07		19/06	08/03	15/05	01/11
	29/07		24/06	21/03	22/05	03/11
	03/08		04/07	31/03	27/05	11/11
	08/08		09/07	05/04	30/05	13/11
	13/08		14/07	07/04	11/06	16/11
	23/08		03/08	12/04	14/06	21/11
	07/09		13/08	17/04	16/06	23/11
	27/09		28/08	22/04	21/06	28/11
	17/10		12/09	30/04	24/06	01/12
	27/10		02/10	02/05	26/06	06/12
	01/11		07/10	07/05	29/06	08/12
	11/11		27/10	15/05	01/07	11/12
	16/11		11/11	22/05	06/07	13/12
	16/12		16/11	27/05	11/07	16/12
	21/12		21/11	30/05	14/07	18/12
	26/12		01/12	06/06	16/07	21/12
	26/12		06/12	09/06	31/07	23/12

TAB. A.8 – Suite et fin du Tableau A.7.

	<i>T32NMK</i>	<i>T32NML</i>	<i>T32NMM</i>	<i>T32NNK</i>	<i>T32NNL</i>	<i>T32NNM</i>
Dates	26/12		11/12	11/06	03/08	26/12
	26/12		16/12	14/06	05/08	28/12
	26/12		21/12	21/06	08/08	
	26/12		26/12	24/06	10/08	
	26/12		26/12	26/06	13/08	
	26/12		26/12	29/06	15/08	
				01/07	18/08	
				06/07	28/08	
				09/07	04/09	
				11/07	12/09	
				14/07	14/09	
				29/07	19/09	
				08/08	22/09	
				13/08	27/09	
				15/08	29/09	
				02/09	07/10	
				19/09	09/10	
				22/09	19/10	
				29/09	24/10	
				17/10	27/10	
				19/10	03/11	
				24/10	11/11	
				27/10	16/11	
				01/11	18/11	
				03/11	23/11	
				11/11	28/11	
				16/11	01/12	
				18/11	06/12	
				23/11	11/12	
				28/11	13/12	
				13/12	16/12	
				16/12	18/12	
				18/12	21/12	
				21/12	23/12	
				23/12	26/12	
				26/12	28/12	

TAB. A.9 – Images disponibles pour la série temporelle composée d’images Sentinel-2A/-2B de l’année 2018 acquises pour les cinq tuiles restantes sur la deuxième zone d’étude (ZONE2) (nomenclature ESA).

	<i>T32NPK</i>	<i>T32NPM</i>	<i>T32NQK</i>	<i>T32NQL</i>	<i>T32NQM</i>
Dates	07/01	10/04	07/01	07/01	22/04
	12/01	12/04	12/01	12/01	27/04
	17/01	17/04	17/01	17/01	02/05
	22/01	20/04	22/01	22/01	07/05
	27/01	22/04	27/01	27/01	22/05
	01/02	27/04	01/02	01/02	06/06
	06/02	30/04	06/02	06/02	11/06
	11/02	02/05	11/02	11/02	16/06
	21/02	07/05	21/02	21/02	21/06
	03/03	15/05	26/02	03/03	26/06
	13/03	20/05	03/03	13/03	01/07
	02/04	22/05	23/03	18/03	06/07
	07/04	25/05	12/04	23/03	11/07
	17/04	27/05	17/04	12/04	31/07
	22/04	01/06	22/04	17/04	10/08
	02/05	04/06	02/05	22/04	15/08
	07/05	06/06	07/05	07/05	20/08
	22/05	09/06	22/05	27/05	30/08
	27/05	11/06	27/05	06/06	04/09
	06/06	14/06	06/06	11/06	14/09
	11/06	16/06	16/06	16/06	19/09
	21/06	21/06	21/06	21/06	29/09
	26/06	26/06	26/06	26/06	04/10
	11/07	01/07	11/07	01/07	09/10
	31/07	06/07	16/07	11/07	19/10
	23/07	11/07	31/07	31/07	29/10
	10/08	16/07	10/08	05/08	03/11
	25/08	24/07	15/08	15/08	13/11
	14/09	31/07	30/08	20/08	18/11
	19/09	03/08	14/09	25/08	23/11
	09/10	08/08	19/09	30/08	28/11
	19/10	10/08	24/09	04/09	03/12
	24/10	13/08	29/09	14/09	13/12
	03/11	15/08	09/10	19/09	18/12
	23/11	20/08	19/10	29/09	23/12

TAB. A.10 – Suite et fin du Tableau A.9.

	T32NPK	T32NPM	T32NQK	T32NQL	T32NQM
Dates	28/11	30/08	24/10	09/10	
	03/12	04/09	03/11	19/10	
	13/12	12/09	08/11	24/10	
	18/12	14/09	18/11	03/11	
	23/12	19/09	23/11	08/11	
	28/12	29/09	28/11	13/11	
		07/10	03/12	18/11	
		09/10	08/12	23/11	
		19/10	13/12	28/11	
		27/10	18/12	03/12	
		29/10	23/12	13/12	
		03/11		18/12	
		11/11		23/12	
		13/11		28/12	
		16/11			
		18/11			
		21/11			
		23/11			
		26/11			
		28/11			
		01/12			
		06/12			
		08/12			
		11/12			
		13/12			
		16/12			
		18/12			
		21/12			
		23/12			
		26/12			
		28/12			

Niveau 1C Données ortho-rectifiées en réflectance TOA.

Niveau 2A Données ortho-rectifiées en réflectance TOC après correction atmosphérique avec les masques de nuages (et de leurs ombres), des surfaces en eau et de la neige.

Niveau 3A Synthèses bi-mensuelles ou mensuelles de réflectance TOC constituées de la moyenne pondérée des réflectances TOC de surface des *pixels non-nuageux* obtenues au cours de la période.

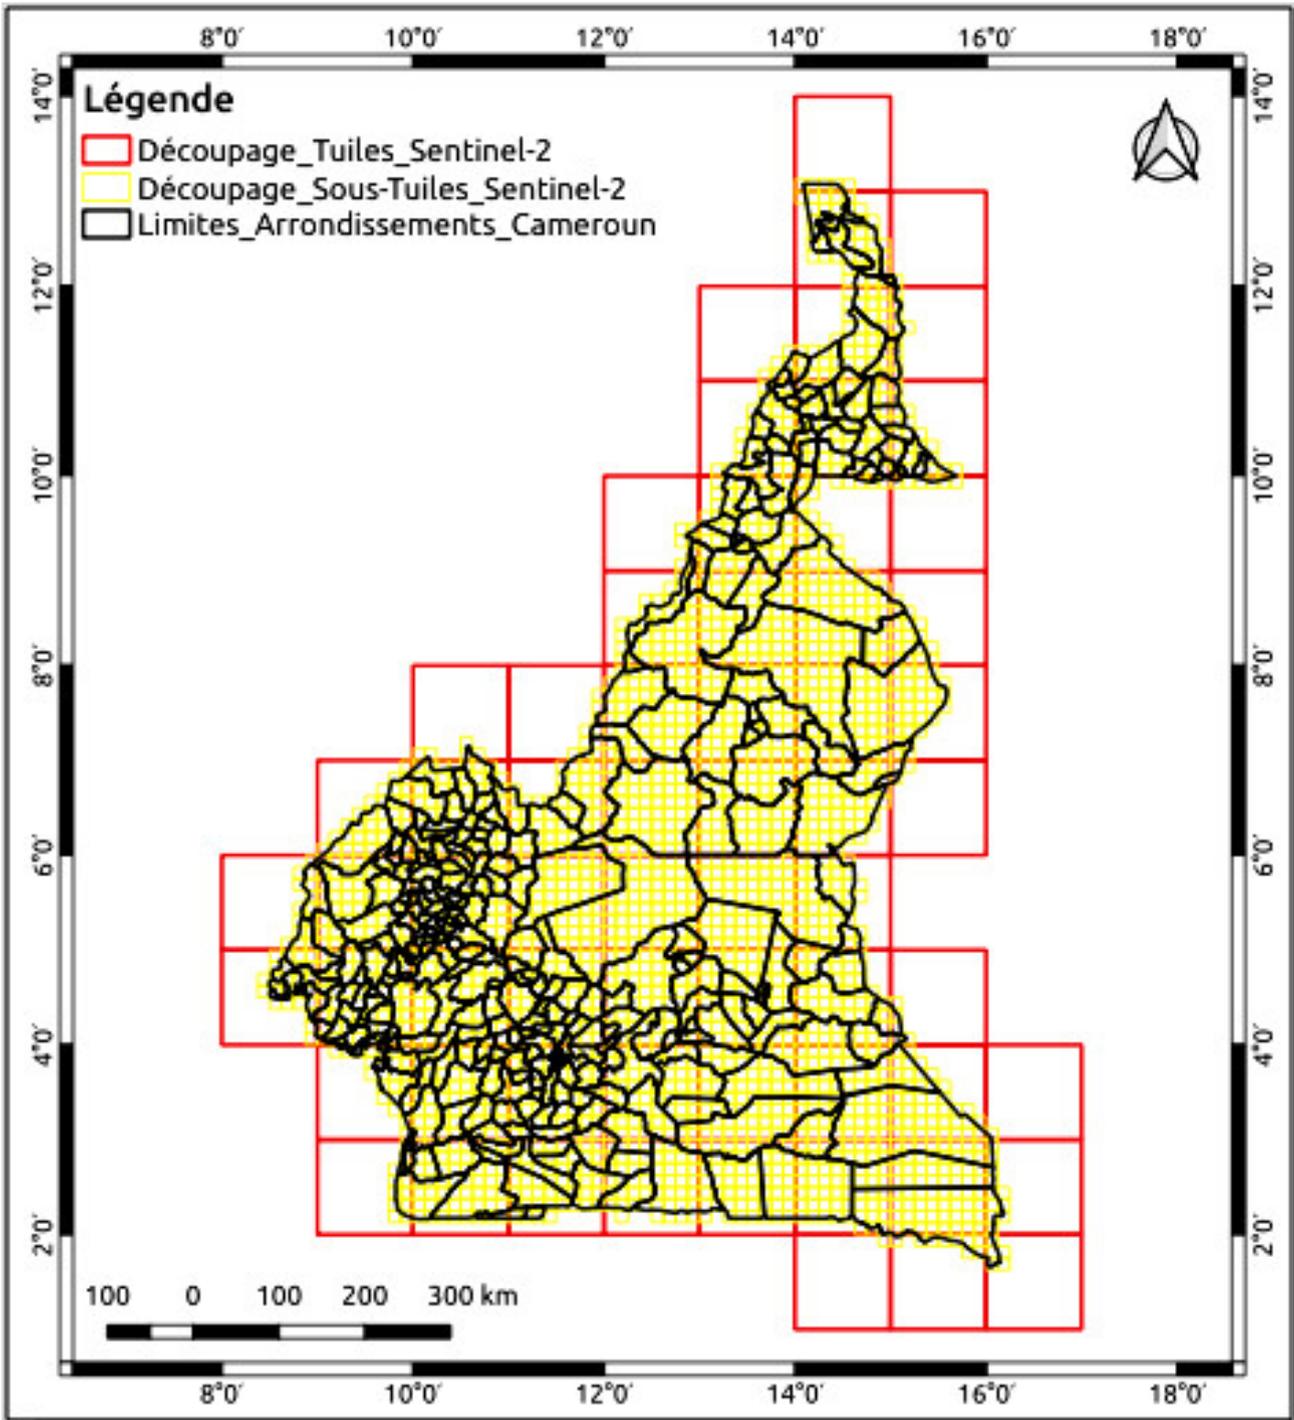


FIG. A.1 – Découpages utilisés lors de la distribution des images Sentinel-2.

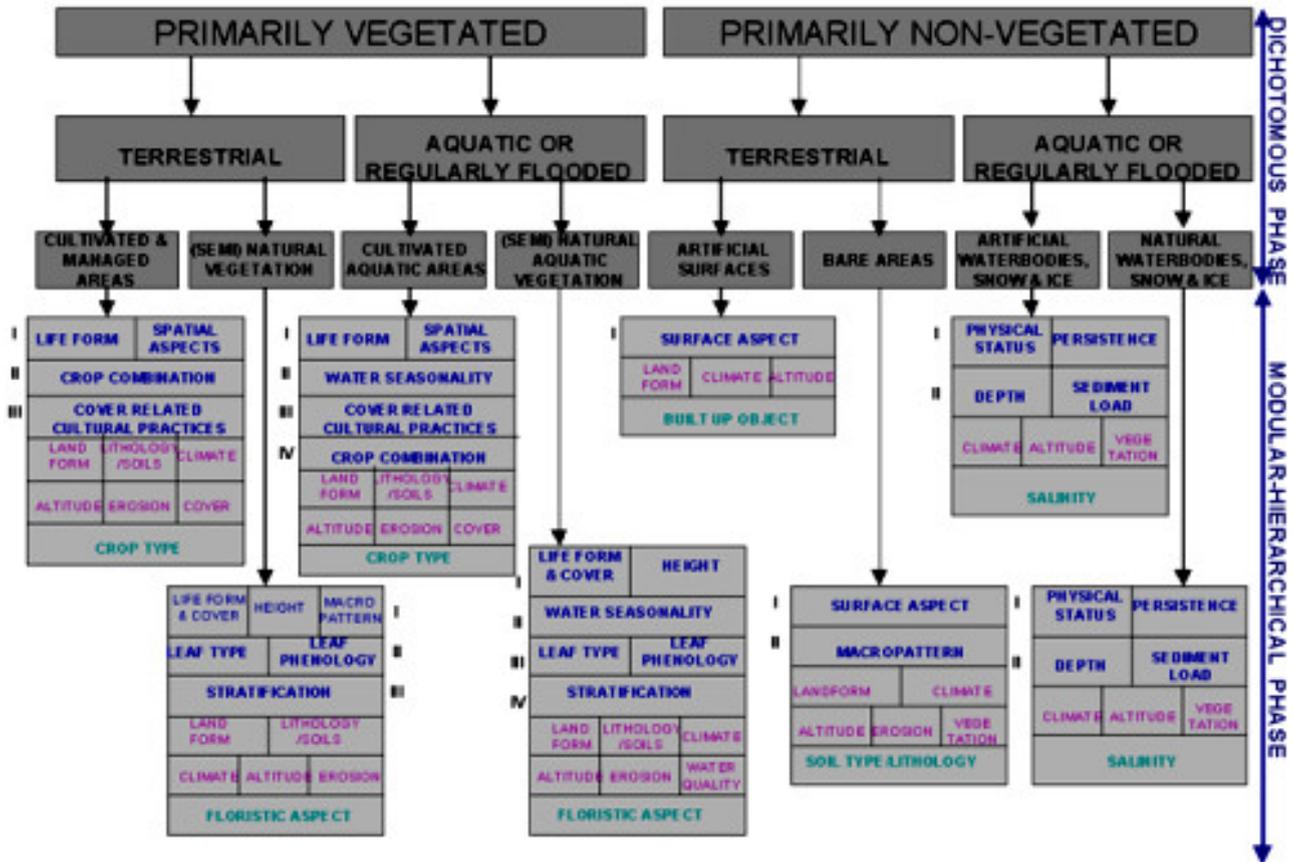


FIG. A.2 – Nomenclature complète LCCS (GREGORIO et JANSEN, 2000).

TAB. A.11 – Nomenclature hiérarchique LCCS (GREGORIO et JANSEN, 2000)

Niveau 1	Niveau 2	Niveau 3
A Principalement végétalisée	A1 Terrestre	A11 Zone terrestre cultivée et gérée
		A12 Végétation terrestre naturelle et semi-naturelle
	A2 Aquatique ou régulièrement inondée	A23 Aquatique cultivée ou régulièrement inondée
		A24 Aquatique naturelle et semi-naturelle ou régulièrement inondée
B Principalement non-végétalisée	B1 Terrestre	B15 Surface artificielle et zone associée
	B2 Aquatique ou régulièrement inondée	B16 Surface nue
		B27 Plan d'eau artificiel, neige et glace
		B28 Plan d'eau naturel, neige et glace

A.4.2 Base de données de l'INC

Le Tableau A.12 détaille uniquement les éléments de la *BD INC* restitués en Ponctuel 2D (P2D), Linéaire 2D (L2D), Surfaccique 2D (S2D), avec leur nature et la méthode de restitution.

Les catégories des éléments de la *BD INC* proviennent soit d'une génération automatique *e.g.* les courbes de niveau, soit de traitements et intégrations ultérieures réalisées par l'INC *e.g.* limites administratives, compléments terrain, etc.

Les valeurs de la colonne « Cat. Restitution » indiquent la catégorie (calque ou *layer*) dans les fichiers de restitution photogrammétrique, avant l'intégration dans la *BDs*.

L'identification des espèces végétales a été réalisée lors de la restitution à partir des images aériennes, en s'aidant également des anciennes cartes existantes, de la carte de la végétation du Cameroun de R Letouzey éditée en 1985, et de l'Atlas Forestier du Cameroun (*World Ressources Institute - wri.org, 2012*)

A.4.3 Légende

La Figure A.3 donne la légende des cartes d'OCS présentées au Chapitre 1.

TAB. A.12 – Éléments restitués et méthode et règles de restitution de la *BD INC*

Cat. <i>BD INC</i>	Cat. Restitution	Type	Modélisation
Type_ZV (TZV)	TZV	P2D	Au centre de l'objet ponctuel (palmier, bananier, cocotier etc.)
Limite_ZV	Limite_ZV	L2D	Tracé des rangés d'arbres – Limite de culture
Zone_Végétation (ZV)	Vegetation	S2D	Contour de la zone de végétation (savane, zone de culture, forêt, prairie, brousse, mangrove, etc.)
Réserves_Forestieres (RF)		S2D	Contour de la réserve
Aires_Protegees (AP)		S2D	Contour de l'aire
Zone_Activite (ZAc)		P2D	Au centre de l'objet ponctuel
Zone_Industrielle (ZI)		P2D	Au centre de l'objet ponctuel
Campement	Campement	P2D	Au centre de l'objet ponctuel
Case	Case	P2D	Au centre de l'objet ponctuel (case ronde)
Bati	Bati_Point	P2D	Au centre de l'objet ponctuel Dans les villes, bâtiment isolé et surface $\leq 500m^2$ Dans les villages, bâtiment isolé et surface $\leq 250m^2$
Bati_Surfacique (BS)	Bati_Surfacique	S2D	Contour du bâtiment au bord de la toiture Dans les villes, surface $\geq 500m^2$ Dans les villages, surface $\geq 250m^2$
Zone_Bati	Zone_Bati	S2D	Contour de la zone urbaine au sol
Surface_Activite (SA)	Surface_Activite	S2D	Limite apparente du site, seulement indicatif (parc, espace vert surface $\geq 500m^2$, site de culture, de loisir etc.)
Cimetière (CIM)	Cimetière	S2D	Contour du cimetière (le mur, le bâtiment (ou la clôture)
Piste_Aerodrome (PA)	Piste_Aerodrome	S2D	Contour de l'ensemble des pistes
Terrain_Sport (TS)	Terrain_Sport	S2D	Contour du terrain
Nature_Sol (NS)	Nature_Sol	S2D	Contour du terrain



Source : amcarto.alwaysdata.net/demo/test/{compa_ocs}.htbpm1

FIG. A.3 – Légende.

Description des données aériennes

Sommaire

B.1	Trajectographie	347
B.2	Stéréopréparation	349
B.3	Aérottriangulation	351

B.1 Trajectographie

La trajectographie est l'enregistrement en vol, en s'appuyant sur des données *GPS/GNSS* (enregistrées par un récepteur *GNSS*) et des données inertielles (enregistrées par une centrale inertielle dite *IMU - Inertial Measurement Unit*), des paramètres de géoréférencement de chacune des images prises, à savoir :

- Coordonnées du centre perspectif de l'image (centre focal de la caméra) : *latitude, longitude, hauteur ellipsoïdale*.
- Angles d'orientation (*roll, pitch, heading*) des faisceaux perspectifs autour des axes X, Y et Z.

Le géoréférencement direct obtenu par la trajectographie post-traitée sera introduit dans le calcul d'aérottriangulation et permettra d'en améliorer la précision tout en réduisant le nombre de points de calage au sol nécessaires par rapport à une méthodologie de calcul d'aérottriangulation classique (sans trajectographie).

Au cours des vols, un récepteur *GPS/GNSS* a été stationné au sol, sur l'aéroport de Douala, et a réalisé des enregistrements de mesures. Il s'agit d'un récepteur bi-fréquence Leica qui offre une précision théoriques de $5\text{mm} + 0,5\text{ppm}$ (*static mode*).

Les paramètres des mesures réalisées seront les suivants :

- Type d'enregistrement : statique.
- Durée d'observation : pendant toute la durée du vol photo.
- Fréquence d'enregistrement des observations : *1 seconde*.
- Angle de coupure minimum : 15° .

Le processus de calcul de la trajectographie dans le système *RGF93* est réalisé avec le logiciel **PosPAC MMS 5.4** d'Applanix.

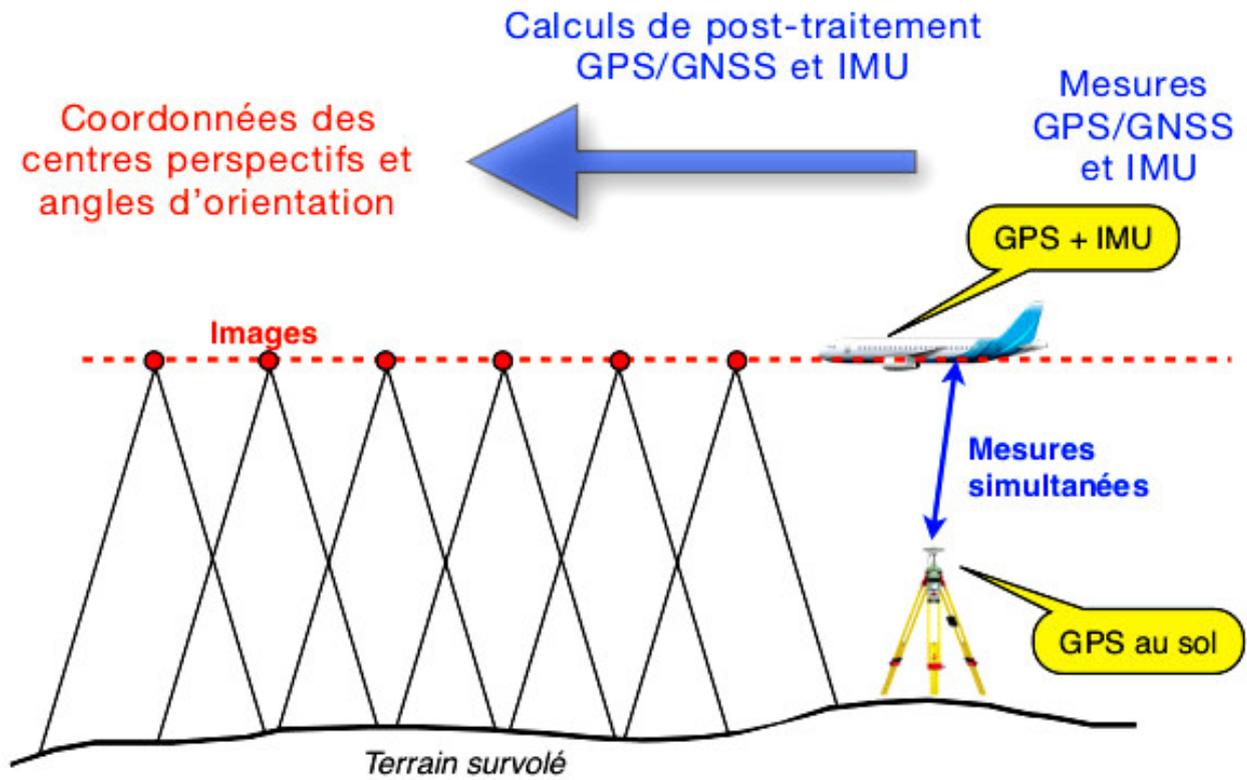


FIG. B.1 – Schéma explicatif du déroulement des mesures de trajectographie.



(A) Vue rapprochée



(B) Vue éloignée

FIG. B.2 – GPS au sol sur l'aéroport de paris CDG au cours d'une prise de vues en 2013.

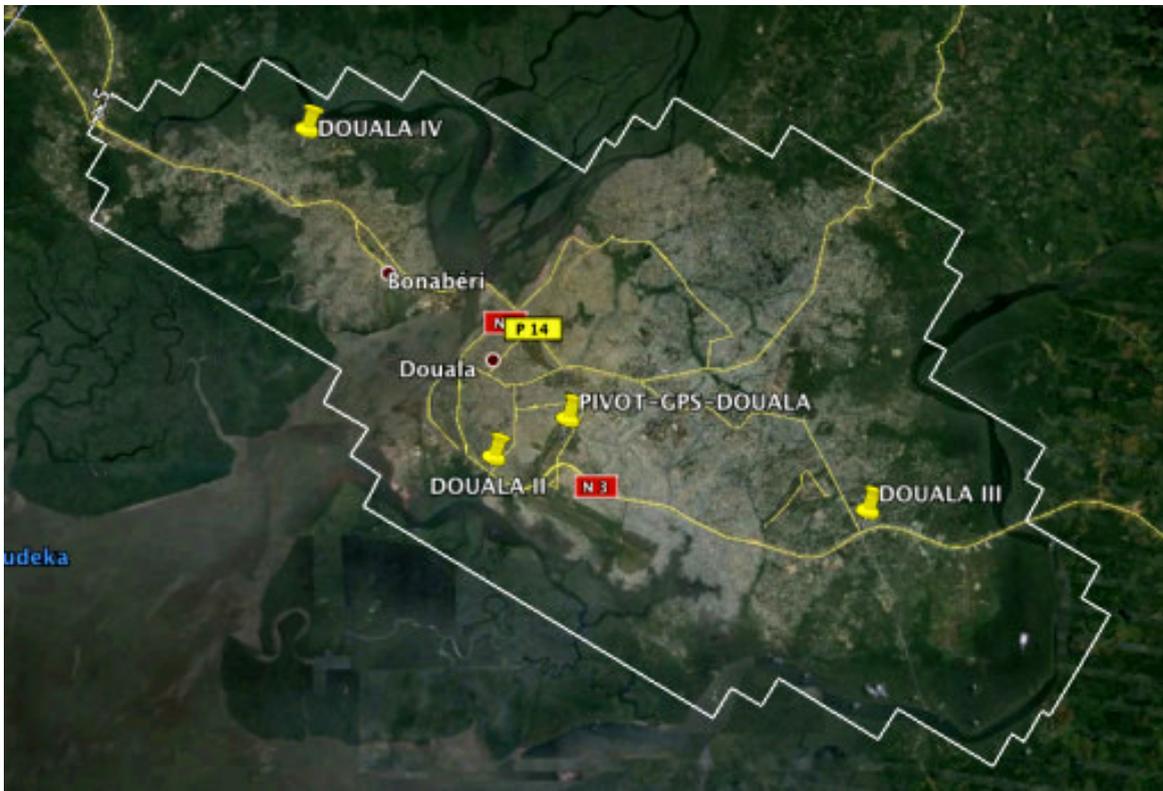


FIG. B.3 – Schéma illustratif de la position du pivot *GPS* au sol (PIVOT-GPS-DOUALA). Les lignes de base aux positions les plus à l’Ouest et à l’Est mesurent au maximum 18 km.

La méthode utilisée dite *Single Base Station*, met en oeuvre une seule station *GNSS* de référence au sol, à partir de laquelle sont calculées les lignes de base aux différentes positions constituant la trajectographie. La technologie *Applanix In-Fusion* permet d’avoir des lignes de base d’une longueur jusqu’à 70 km autour de la référence. En l’espèce, la ligne de base est limitée à 18 km, ce qui permet d’assurer une excellente précision.

Le pivot *GPS* au sol (PIVOT-GPS-DOUALA) est rattaché aux points du *RGC* situés à proximité : DOUALA II, DOUALA III, DOUALA IV. De cette manière, l’ensemble de la trajectographie est rattachée au *RGC*.

B.2 Stéréopréparation

L’ensemble des clichés sont équipés par la réalisation d’environ 20 points de stéréopréparation, qui sont utilisés pour le calage des images, et 5 points de contrôle, utilisés uniquement pour le contrôle de l’aérotriangulation, répartis uniformément sur l’ensemble du territoire.

Une attention particulière est accordée au choix des points de stéréopréparation. Les détails retenus doivent notamment offrir un bon contraste photographique et une bonne définition géométrique. Les détails de type signalisation horizontale, les coins de regards ou encore les intersections de dallages identifiables sans ambiguïté sont privilégiés.

Grâce à une photo d’identification prise à chaque point de stéréopréparation, une fiche comprenant la description succincte du point et un croquis manuel destiné à re-situer le point, est dressée.

Il convient également de noter que la prise de vues est faite avec enregistrement de la trajectographie c’est à dire de la coordonnée du centre de cliché, grâce au capteur *GNSS* (*GPS/GLONASS*) et des



FIG. B.4 – Choix de points de stéréopréparation.

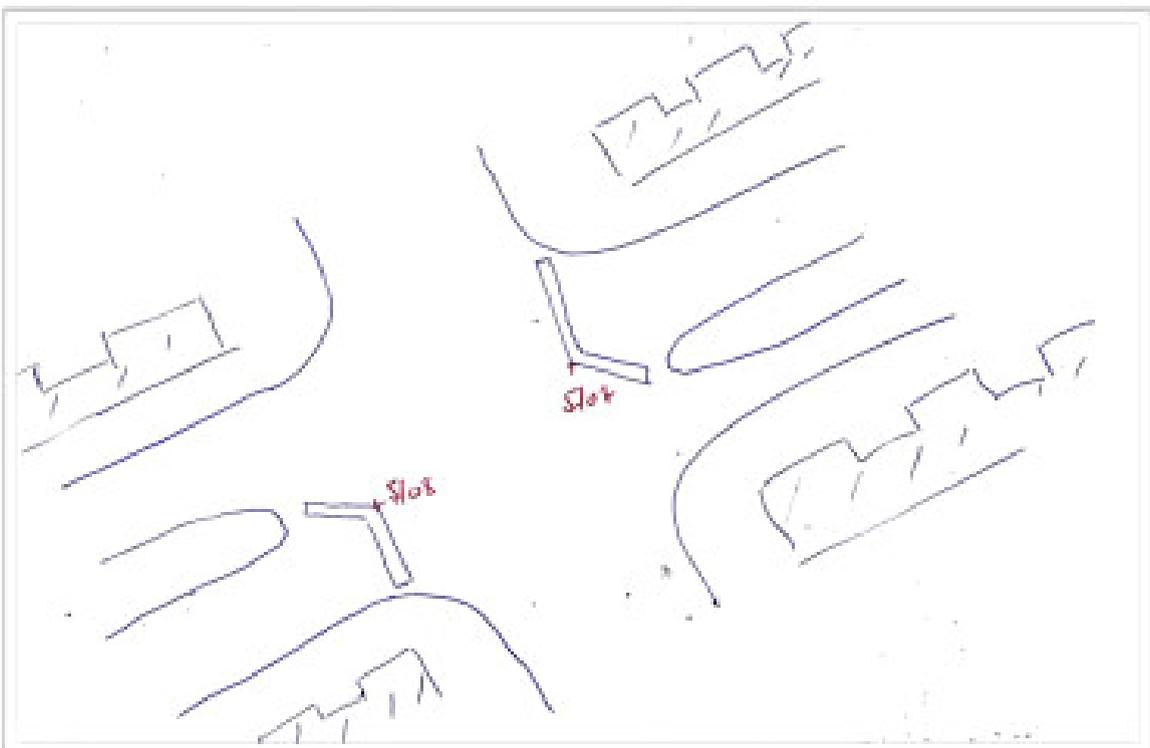


FIG. B.5 – Exemple de croquis de point de stéréopréparation.

angles d'orientation (ω , ϕ , κ) du système de la chambre de prise de vues aériennes, grâce à la centrale inertielle du système. Ces éléments venant en complément de la stéréopréparation sont intégrés dans le calcul d'aérotriangulation et permettent d'en améliorer la précision.

Les coordonnées des points de stéréopréparation sont déterminées par GPS bi-fréquence Leica, en coordonnées *UTM32/Altitudes* au dessus du niveau moyen de la mer *EGM2008* en se rattachant aux points géodésiques du RGC à proximité (Douala II, Douala III, Douala IV). Les observations sont effectuées en temps réel, avec un *GPS* fixe, stationné en tant que référence, et un *GPS* mobile communiquant avec la référence par radio ou modem *GSM*, celle-ci leur transmettant la correction différentielle *GPS*.

Afin d'obtenir une précision optimale pour le calage des photos, chaque point de stéréopréparation prévu est doublé ou triplé. De cette manière, il est possible d'utiliser lors du calage les points donnant les meilleurs résultats. De plus, les points de stéréopréparation qui n'ont pas été utilisés pour le calage des clichés servent ensuite comme points de contrôle de l'aérotriangulation et de l'orthophotoplan.

Compte tenu de la méthodologie employée et de la précision des points de rattachement, la précision planimétrique et altimétrique des coordonnées des points de stéréopréparation satisfait aisément aux exigences de précision pour la réalisation de l'aérotriangulation. En effet, les points de stéréopréparation ont une classe de précision planimétrique de 3 *cm* et une classe de précision altimétrique de 3 *cm*.

B.3 Aérotriangulation

Le calcul de l'aérotriangulation est réalisé avec le logiciel **ORIMA-TE GPS** de Leica. Ce programme, non limité en nombre d'images, nous permet d'effectuer le calcul de compensation de l'ensemble des couples stéréoscopiques et d'intégrer rigoureusement la trajectographie (coordonnées *XYZ* des centres perspectifs, angles ω , ϕ , κ d'orientation des faisceaux perspectifs).

Les opérations d'aérotriangulation se font sur les images panchromatiques afin de favoriser la recherche des points de liaison par corrélation, qui est meilleure. Le processus de travail peut être décomposé en trois principales parties :

1. Chargement des images, de la trajectographie, saisie automatique des points de liaison.

La saisie des points de liaison inter-clichés est automatique à partir du premier cliché gauche de chacune des bandes constituant le bloc ; les points de liaison inter-bandes sont saisis de la même manière après que toutes les bandes aient été traitées. La saisie automatique permet d'avoir une densité de points très importante (en général, entre 90 et 180 points de liaison par image), et donc contribue à assurer la précision du calcul grâce à la précision du pointé automatique (par corrélation) et grâce à une très forte redondance résultant du grand nombre de points saisis, qui permet de détecter et d'éliminer les points de liaison erronés. Les points de liaison automatique sont ensuite filtrés afin d'éliminer les grosses erreurs en ne privilégiant que ceux présents dans les zones de Von Grüber.

2. Saisie manuelle de points de stéréopréparation et le cas échéant de points de liaison supplémentaires.

La saisie manuelle des points de stéréopréparation et des points de liaison supplémentaires s'effectue en mode monoscopique (*Split*) ou en stéréoscopie, sur toutes les images sur lesquelles ce point est visible.

3. Calcul d'ajustement du bloc (compensation par faisceaux).

Le calcul d'ajustement utilise en entrée les points de stéréopréparation ainsi que les paramètres d'orientation fournis par les mesures *DGPS/IMU*, pondérés avec leur précision réelle (écarts types à posteriori fournis par les programmes de calcul de la trajectographie et de calculs *GPS*).

Le mode de présentation des résultats d'**ORIMA** repose essentiellement sur la visualisation graphique des résultats de l'orientation et des données saisies en aérotriangulation grâce à laquelle **ORIMA** facilite et accélère la saisie et la lecture des informations disponibles. **ORIMA** contrôle en continu toutes les mesures à l'aide de méthodes statistiques. L'opérateur visualise graphiquement la qualité des paramètres d'orientation calculés, par le biais d'écarts types à posteriori et ellipses d'erreur. Les paramètres de la chambre de prise de vues (la focale et les valeurs de la distorsion), la rotondité de la terre et la réfraction atmosphérique sont pris en compte lors du calcul.

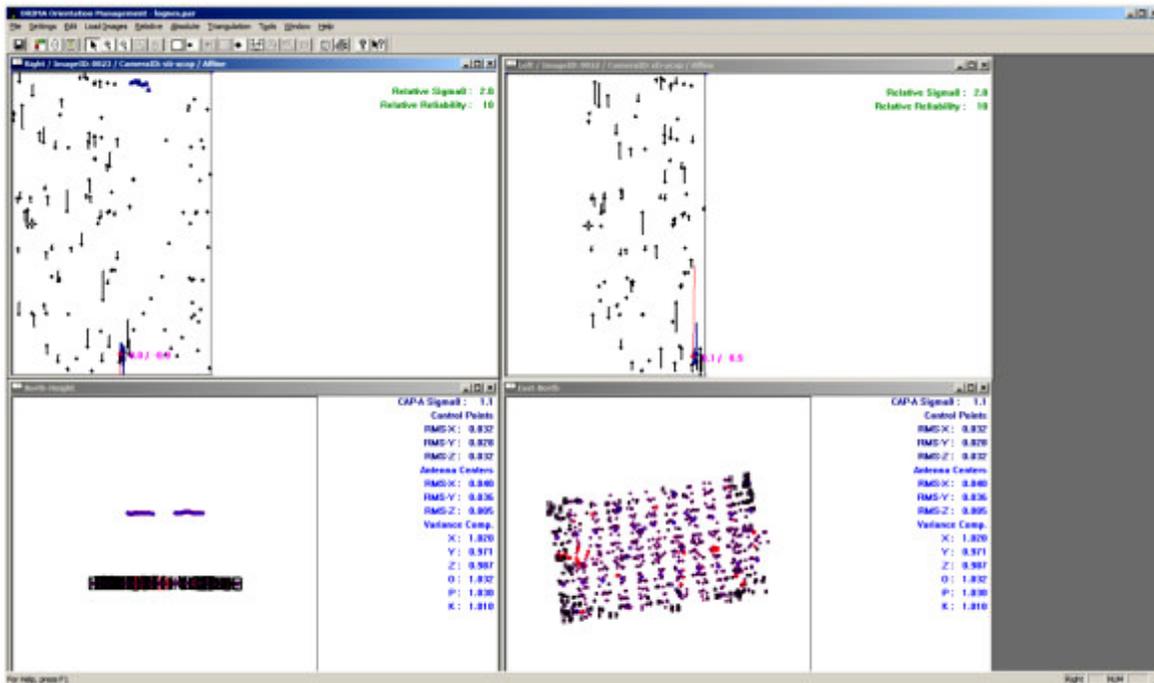


FIG. B.6 – Ecran principal d'un projet d'aérotriangulation avec **ORIMA**. Les deux fenêtres supérieures représentent les images (gauche et droite) du couple chargé avec les points de liaison réalisés et leur vecteur d'erreur associé. Les deux fenêtres inférieures donnent un aperçu global du bloc (North/height et East/North) avec les points de liaison, les points d'appui, les centres perspectifs, et les ellipses d'erreur associées.

Le résultat du calcul fournit pour chaque centre de prise de vues les valeurs des coordonnées *XYZ* et des angles d'orientation ω , ϕ , κ qui sont nécessaires pour l'exploitation ultérieure de ces images par exemple pour une restitution photogrammétrique ou bien la réalisation d'un MNT ou d'une orthophotographie.

Processus de prise de vues aériennes Le processus de travail est le suivant :

- Le projet de plan de vol est conçu à l'aide du logiciel **snapPLAN de Track'Air**. Celui-ci permet notamment de calculer automatiquement la couverture photo d'une zone, à partir des paramètres (taille pixels, recouvrements, etc.) et des tolérances introduits. Le logiciel tient compte notamment du relief (*MNT*) pour le calcul des hauteurs de vol et de la position des clichés, afin d'assurer les recouvrements longitudinaux et latéraux requis.

- Le plan de vol, avec tous ses paramètres (hauteurs de vol *MSL* de chaque axe, coordonnées de chaque axe, position pré-calculée de chacun des clichés, etc) est importé dans le système de navigation embarquée **Track'Air POSTrack**.
- En vol, au passage du récepteur *GPS* dans sa fenêtre de tolérance, le cliché est déclenché automatiquement. A cet instant deux données sont enregistrées : la coordonnée du centre de cliché grâce au capteur *GNSS*, et les angles d'orientation (ω , ϕ , κ) du système de la chambre de prise de vues aériennes, grâce à la centrale inertielle du système. Pour une plus grande fiabilité, celle-ci est intégrée directement à l'intérieur de la caméra Vexcel.
- Pendant le vol, des récepteurs au sol enregistrent des mesures, de manière à obtenir la donnée différentielle d'acquisition *GPS* : ces données sont ensuite introduites dans le post-traitement pour calculer la trajectographie.



FIG. B.7 – Caméra Microsoft Ultracam Xp avec sa monture *GSM3000*.

La caméra est associée à une **monture gyrostabilisée Ultramount GSM 3000**. Celle-ci permet une stabilisation dynamique de la caméra sur les trois axes de rotation, par le biais d'un mécanisme hydraulique, et ainsi d'éliminer les erreurs angulaires et les mouvements d'image au moment de l'exposition. La caméra est également couplée à un **système de géoréférencement GNSS/INS Applanix POS AV 510**, comprenant la **trajectographie DGPS** (capteur GPS et GLONASS) et une centrale inertielle « *Inertial Measurement Unit (IMU)* ».

Les données de trajectographie, une fois post-traitées, seront introduites dans le calcul d'aérotriangulation et permettront d'en améliorer la précision tout en réduisant le nombre de points de calage au sol nécessaires.

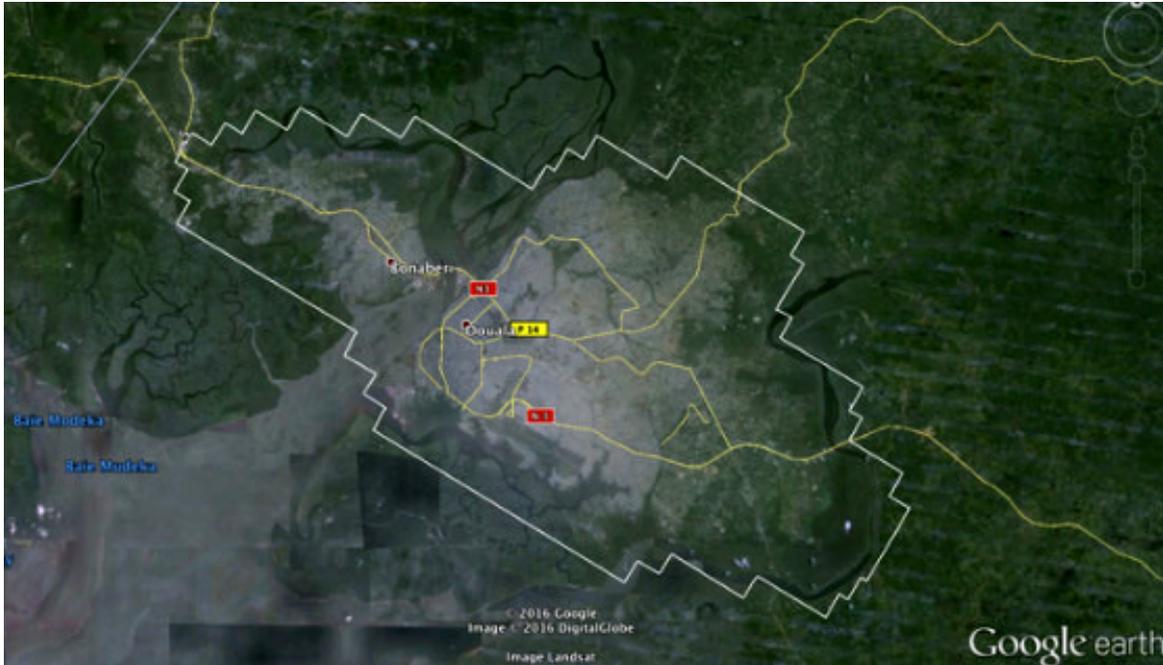
Plan de vol et caractéristiques de la prise de vues réalisée L'altitude de vol *MSL* « *mean sea level* » de chaque axe est calculée individuellement en fonction du relief, ceci afin que la taille du pixel native prévue (9 cm) soit assurée au mieux, pour chacune des bandes, et pour chacune des images de chaque bande.

TAB. B.1 – Conditions atmosphériques choisies pour effectuer le vol.

Vitesse du vent	25 m/s maxi
Nébulosité	0/8
Visibilité	plus de 10 km
Hauteur du Soleil	plus de 30°
Turbulences	modérées
Précipitations	absentes

TAB. B.2 – paramètres du vol.

Surface photographiée	402 km ²
Taille du pixel au sol	9 cm GSD natif
Taille du pixel sur le CCD	6 microns
Taille de l'image	11310 pixels x 17310 pixels
Focale	100,5 mm
Nombre d'axes de vol	15
Nombre d'images	873
Nombre de couples stéréoscopiques	858
Échelle de la prise de vues	1/15 000 ème
Recouvrement minimum entre images	60 %
Recouvrement minimum entre axes de vol	30 %
Hauteur de vol « Above Ground Level (AGL) »	4946 pieds (1508 mètres)



Source : Google Earth <https://www.google.com/earth>

FIG. B.8 – Emprise de la prise de vues couvrant la zone Littoral Cameroun et environs sur une surface d'environ 402 km^2 .

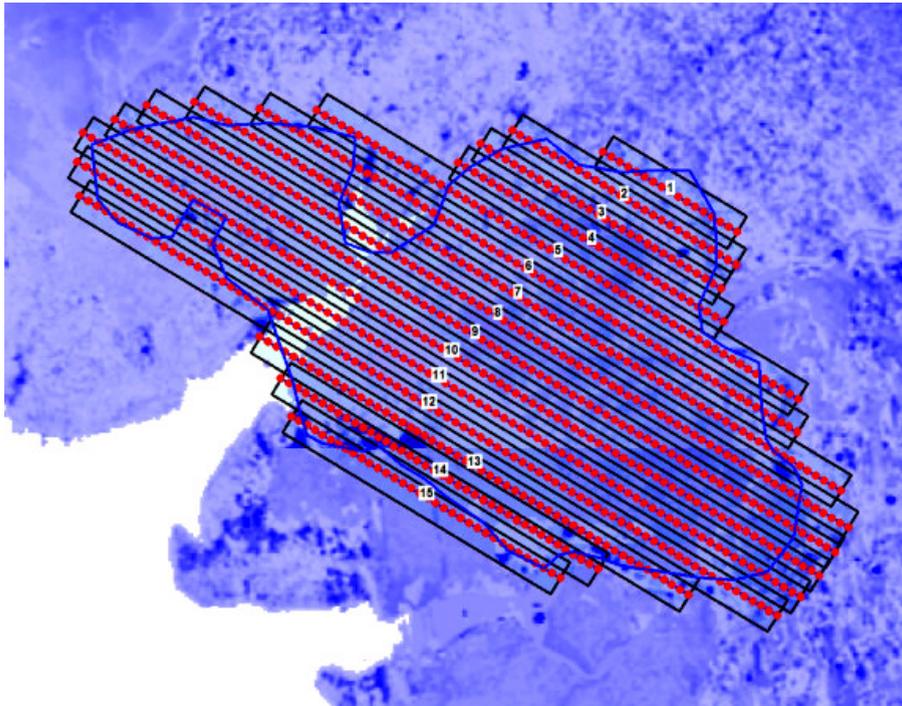


FIG. B.9 – Aperçu du plan de vol sur la zone Littoral Cameroun et environs sur fond de plan hypsométrique.

Outils logiciels utilisés

Sommaire

C.1	Outil logiciel de traitement d'images géospatiales	359
	C.1.1 <i>MAJA</i>	359
	C.1.2 <i>WASP</i>	359
	C.1.3 <i>SNAP</i>	360
	C.1.4 <i>MICMAC</i>	360
C.2	Outil logiciel d'analyse des résultats de classification	360
	C.2.1 <i>QGIS</i>	360

Dans l'ensemble de ces travaux de thèse, nous avons fait le choix d'utiliser les outils logiciels libres d'accès pour le traitement et l'analyse des données.

C.1 Outil logiciel de traitement d'images géospatiales

C.1.1 *MAJA*

MAJA (*MACCS ATCOR Joint Algorithm*) est une chaîne de détection de nuages et de correction atmosphérique. Elle est adaptée au traitement de séries temporelles d'images à haute résolution acquises sous des angles de vue constants ou quasi constants. Elle permet notamment de traiter les données issues des capteurs Sentinel-2 et Landsat. Elle se fonde sur la chaîne *MACCS* développée par le CNES et le CESBIO depuis 2008, et incorpore progressivement depuis 2016 des méthodes issues de la chaîne *ATCOR* du DLR. Elle fait donc maintenant l'objet d'une collaboration entre le CNES, le DLR et le CESBIO, et bénéficie du soutien financier de l'ESA.

La particularité de la chaîne *MAJA* réside dans l'utilisation d'information multi-temporelle contenue dans les images pour détecter les nuages et leurs ombres, estimer le contenu atmosphérique en aérosols et en vapeur d'eau, et corriger les effets atmosphériques (en prenant en compte les effets d'environnement et les effets du relief). Plus de détails sur les méthodes associées à cette chaîne se trouve sur le site : <https://labo.obs-mip.fr/multitemp/maccs-comment-ca-marche/> et le lien de téléchargement et d'installation de la chaîne est le suivant : <https://logiciels.cnes.fr/fr/content/maja>.

C.1.2 *WASP*

WASP (*Weightbped Average Synthesis Processor*) est une chaîne de traitement permettant de synthétiser plusieurs images optiques Sentinel-2 après le passage en réflectance du niveau 1C (*Level 1C (L1C)*)

au niveau 2A (*Level 2A (L2A)*) à l'aide de la chaîne de *MAJA* (HAGOLLE et al., 2015a) en une seule image sans nuages. Elle permet donc de créer périodiquement des images de synthèse sans nuages de niveau 3A (*Level 3A (L3A)*) tout en conservant la saisonnalité (pour la classification par exemple). Elle supporte actuellement les plateformes Sentinel-2 et Venus. L'algorithme de la chaîne *WASP* a été développé au CESBIO en coopération avec l'Université Catholique de Louvain (UCL) et CS Romania dans le cadre du projet Sen2Agri qui a bénéficié d'un financement de l'ESA.

La chaîne *WASP* fonctionne sur le format de produit de niveau 2A (*Level 2A (L2A)*) défini par le pôle de données et de services surfaces continentales THEIA. Des exemples de produits sont disponibles sur le site web du centre de données terrestres de THEIA : <https://theia.cnes.fr/>. Plus de détails sur les méthodes utilisées par la chaîne *WASP* peuvent être consultés sur le site : <http://www.cesbio.ups-tlse.fr/multitemp/?p=13976> et le lien de téléchargement et d'installation de la chaîne se trouve ici : <https://github.com/CNES/WASP>.

C.1.3 SNAP

SNAP (SeNtinel Application Platform) est une architecture commune développée conjointement par Brockmann Consult, SkyWatch et CS pour toutes les boîtes à outils Sentinel. Cette plateforme est développée pour pouvoir exploiter les données du programme Copernicus. Les fonctions de base de l'architecture sont les suivantes : ouvrir un produit, explorer les composants du produit tels que des bandes, des masques et des grilles de points de rattachement. Les outils de navigation et la fonctionnalité d'information sur les pixels représentent également certaines des fonctionnalités de base. Les boîtes à outils Sentinel contiennent des outils de manipulation d'images capables de traiter des images de plusieurs giga-pixels. Elles sont donc adaptées pour travailler avec des images satellites de grandes tailles (<http://step.esa.int/main/download/>).

Au cours des travaux, l'architecture *SNAP* a été utilisée essentiellement pour les pré-traitements des images radar Sentinel-1. Notamment : 1) la correction géométrique, et 2) la calibration radiométrique.

C.1.4 MICMAC

MICMAC (Multi-Images Correspondances, Méthodes Automatiques de Corrélation) est un logiciel développé à l'IGN dans l'objectif de fournir une solution unifiée permettant de répondre à la majorité des problèmes de photogrammétrie, de la mise en place des images à la production de MNS (par appariement dense) et d'ortho-images. La littérature propose, en général, de nombreuses solutions. À l'IGN, des solutions opérationnelles *ad hoc*, différentes pour chaque catégorie de problème, ont été mises en oeuvre dans les services de production. Depuis juin 2007, il est diffusé en tant que logiciel libre (*open source*) et fonctionne sous Linux, Mac et Windows. Le logiciel *MICMAC* est accessible à cette adresse : <http://www.micmac.ign.fr/svn/micmac/> (la documentation se trouve dans le dossier : Documentation/DocMicMac/DocMicMac.pdf)

C.2 Outil logiciel d'analyse des résultats de classification

C.2.1 QGIS

QGIS est un logiciel SIG (système d'information géographique) initialement appelé *Quantum GIS* jusqu'en septembre 2013 (<https://www.qgis.org/fr/site/>). Le logiciel *QGIS* a été utilisée uniquement pour la visualisation des données et des résultats.

Résultats des comparaisons

Sommaire

D.1	Comparaison pixel à pixel	363
D.1.1	Zone d'intérêt <i>T33PUL</i>	363
D.1.2	Zone d'intérêt <i>T32NPL</i>	365
D.1.3	Zone d'étude <i>ZONE1</i>	378
D.2	Comparaison par régions des distributions de classes	380
D.2.1	Zone d'intérêt <i>T33PUL</i>	380
D.2.2	Zone d'intérêt <i>T32NPL</i>	389
D.2.3	Zone d'étude <i>ZONE1</i>	397

Les résultats obtenus au terme des comparaisons pixel à pixel et des distributions de classes par région des différentes classifications ainsi que leurs diverses fusions tardives produites, sont présentés dans les tableaux ci-après.

D.1 Comparaison pixel à pixel

D.1.1 Zone d'intérêt *T33PUL*

D.1.1.1 Auto-entraînement sur l'étendue d'une tuile Sentinel-2

D.1.1.1.1 En absence d'images Sentinel-1

Classifications

Le Tableau D.1 présente les différentes valeurs du coefficient Kappa (K) et du F-Score moyen (FS) obtenues au terme de la comparaison pixel à pixel des classifications de séries temporelles d'images optiques Sentinel-2 *L2A* des douze mois et de l'année complète 2018 et de la VT en utilisant la légende à 12 classes, de la zone d'intérêt *T33PUL*.

D.1.1.1.2 En présence d'images Sentinel-1

Classifications

Le Tableau D.2 présente les différentes valeurs du coefficient Kappa (K) et du F-Score moyen (FS) obtenues au terme de la comparaison pixel à pixel des classifications de séries temporelles d'images

TAB. D.1 – Coefficients Kappa (K) et F-Scores moyens (FS) obtenus au terme de la comparaison pixel à pixel des classifications de séries temporelles d'images optiques Sentinel-2_L2A et de la VT avec la légende à 12 classes, de la zone d'intérêt T33PUL.

	jan.			fév.			mar.			avr.			mai			juin			juil.			août.			sep.			oct.			nov.			déc.			2018			VT		
<i>k</i> = 12	K	FS	K	K	FS	K	K	FS	K	K	FS	K	K	FS	K	K	FS	K	K	FS	K	K	FS	K	K	FS	K	K	FS	K	K	FS	K	K	FS	K	K	FS	K			
L2A																																										
janvier	1,0	100,0	0,5	11,6	0,1	11,6	0,4	40,2	0,1	9,2	0,3	37,0	0,2	32,8	0,1	23,9	0,1	8,6	0,4	46,3	0,4	45,5	0,5	50,4	0,2	12,7	0,1	2,2														
février	0,5	51,8	1,0	100,0	0,1	11,4	0,4	38,1	0,1	9,5	0,3	41,0	0,2	32,9	0,1	20,3	0,1	9,4	0,4	40,8	0,4	40,3	0,4	43,6	0,2	12,8	0,1	1,5														
mars	0,1	11,6	0,1	11,4	1,0	100,0	0,1	8,6	0,3	27,0	0,1	8,7	0,1	6,9	0,1	5,5	0,2	31,6	0,1	10,1	0,1	9,8	0,1	11,0	0,4	47,4	0,3	29,1														
avril	0,4	40,2	0,4	38,1	0,1	8,6	1,0	100,0	0,1	7,9	0,3	34,3	0,2	32,1	0,1	24,3	0,1	7,4	0,3	36,1	0,3	36,2	0,3	37,5	0,2	10,1	0,1	1,5														
mai	0,1	9,2	0,1	9,5	0,3	27,0	0,1	7,9	1,0	100,0	0,1	11,6	0,1	8,6	0,1	6,8	0,2	23,2	0,1	9,0	0,1	9,0	0,1	9,4	0,3	32,1	0,2	19,3														
juin	0,3	37,0	0,3	41,0	0,1	8,7	0,3	34,3	0,1	11,6	1,0	100,0	0,3	37,4	0,1	21,9	0,1	10,0	0,3	39,8	0,3	38,9	0,3	38,0	0,2	13,4	0,1	18,1														
juillet	0,2	32,8	0,2	32,9	0,1	6,9	0,2	32,1	0,1	8,6	0,3	37,4	1,0	100,0	0,1	27,4	0,1	8,1	0,3	34,1	0,2	32,9	0,2	32,5	0,1	9,7	0,1	1,3														
août	0,1	23,9	0,1	20,3	0,1	5,5	0,1	24,3	0,1	6,8	0,1	21,9	0,1	27,4	1,0	100,0	0,1	6,2	0,1	23,8	0,1	22,9	0,1	23,2	0,1	6,6	0,1	1,6														
septembre	0,1	8,6	0,1	9,4	0,2	31,6	0,1	7,4	0,2	23,2	0,1	10,0	0,1	8,1	0,1	6,2	1,0	100,0	0,1	10,3	0,1	9,1	0,1	9,4	0,3	38,3	0,1	22,2														
octobre	0,4	46,3	0,4	40,8	0,1	10,1	0,3	36,1	0,1	9,0	0,3	39,8	0,3	34,1	0,1	23,8	0,1	10,3	1,0	100,0	0,5	50,5	0,5	48,9	0,2	13,7	0,1	2,9														
novembre	0,4	45,5	0,4	40,3	0,1	9,8	0,3	36,2	0,1	9,0	0,3	38,9	0,2	32,9	0,1	22,9	0,1	9,1	0,5	50,5	1,0	100,0	0,6	51,4	0,2	12,9	0,1	2,4														
décembre	0,5	50,4	0,4	43,6	0,1	11,0	0,3	37,5	0,1	9,4	0,3	38,0	0,2	32,5	0,1	23,2	0,1	9,4	0,5	48,9	0,6	51,4	1,0	100,0	0,2	13,5	0,1	2,7														
2018	0,2	12,7	0,2	12,8	0,4	47,4	0,2	10,1	0,3	32,1	0,2	13,4	0,1	9,7	0,1	6,7	0,3	38,3	0,2	13,7	0,2	12,9	0,2	13,5	1,0	100,0	0,2	30,6														
VT	0,1	2,2	0,1	1,5	0,3	29,1	0,1	1,5	0,2	19,3	0,1	1,8	0,1	1,3	0,1	1,6	0,1	22,2	0,1	2,9	0,1	2,4	0,1	2,7	0,2	30,6	1,0	100,0														

k : nombre de classes. VT : vérité terrain.

optiques et radar Sentinel-1_L1/-2_L2A des douze mois et de l'année complète 2018 et de la VT en utilisant la légende à 12 classes, de la zone d'intérêt T33PUL.

Fusions de classifications

Le Tableau D.3 présente les différentes valeurs du coefficient Kappa (K) et du F-Score moyen (FS) obtenues au terme de la comparaison pixel à pixel de la classification de l'année complète 2018 et des onze fusions de classifications mensuelles de séries temporelles d'images optiques et radar Sentinel-1_L1/-2_L2A et de la VT en utilisant la légende à 12 classes, de la zone d'intérêt T33PUL.

D.1.1.2 Sensibilité aux périodes de synthèse mensuelle de séries temporelles d'images Sentinel-2

D.1.1.2.1 En absence d'images Sentinel-1

Classifications

5 classes Les Tableaux D.4, D.5 et D.6 présentent les différentes valeurs du coefficient Kappa (K) et du F-Score moyen (FS) obtenues au terme de la comparaison pixel à pixel des classifications des différentes synthèses mensuelles de périodes 45, 105 et 165 et de leurs synthèses fusions respectives 2018_P45, 2018_P105 et 2018_P165 de séries temporelles d'images optiques Sentinel-2_L3A et de la vérité terrain (VT) avec la légende à 5 classes, de la zone d'intérêt T33PUL.

D.1.1.2.2 En présence d'images Sentinel-1

Classifications

5 classes Les Tableaux D.7, D.8 et D.9 présentent les différentes valeurs du coefficient Kappa (K) et du F-Score moyen (FS) obtenues au terme de la comparaison pixel à pixel des classifications des différentes synthèses mensuelles de périodes 45, 105 et 165 et de leurs synthèses fusions respectives 2018_P45, 2018_P105 et 2018_P165 de séries temporelles d'images optiques et radar Sentinel-1_L1/-2_L3A et de la vérité terrain (VT) avec la légende à 5 classes, de la zone d'intérêt T33PUL.

Fusions de classifications

5 classes Les Tableaux D.10 et D.11 présentent les différentes valeurs du coefficient Kappa (K) et du F-Score moyen (FS) obtenues au terme de la comparaison pixel à pixel respectivement des classifications des synthèses 2018_P45 et 2018_P315 ainsi que des onze fusions de classifications des synthèses mensuelles de période 45 jours de séries temporelles d'images optiques et radar Sentinel-1_L1/-2_L3A et de la vérité terrain (VT) avec la légende à 5 classes, de la zone d'intérêt T33PUL.

D.1.2 Zone d'intérêt T32NPL

D.1.2.1 Auto-entraînement sur l'étendue d'une tuile Sentinel-2

D.1.2.1.1 En absence d'images Sentinel-1

Classifications

Le Tableau D.12 présente les différentes valeurs du coefficient Kappa (K) et du F-Score moyen (FS) obtenues au terme de la comparaison pixel à pixel des classifications de séries temporelles d'images optiques Sentinel-2_L2A des douze mois et de l'année complète 2018 et de la VT en utilisant la légende à 12 classes, de la zone d'intérêt T32NPL.

TAB. D.2 – Coefficients Kappa (K) et F-Scores moyens (FS) obtenus au terme de la comparaison pixel à pixel des classifications de séries temporelles d'images optiques et radar Sentinel-1_L1/-2_L2A et de la VT avec la légende à 12 classes, de la zone d'intérêt T33PULL.

	jan.			fév.			mar.			avr.			mai			juin			juil.			août.			sep.			oct.			nov.			déc.			2018			VT								
<i>k</i> = 12	K	FS	K	K	FS	K	K	FS	K	K	FS	K	K	FS	K	K	FS	K	K	FS	K	K	FS	K	K	FS	K	K	FS	K	K	FS	K	K	FS	K	K	FS	K	K	FS	K						
L1-L2A																																																
janvier	1,0	100,0	0,6	55,8	0,5	49,4	0,4	39,8	0,4	40,1	0,3	40,4	0,2	32,8	0,1	21,7	0,2	31,7	0,4	45,8	0,4	45,5	0,4	45,5	0,5	47,7	0,5	52,2	0,1	2,2																		
février	0,6	55,8	1,0	100,0	0,5	50,0	0,4	39,9	0,3	38,2	0,3	37,6	0,2	31,4	0,1	20,8	0,2	31,1	0,4	41,3	0,4	41,5	0,4	41,5	0,4	44,4	0,5	46,8	0,1	1,8																		
mars	0,5	49,4	0,5	50,0	1,0	100,0	0,4	41,5	0,4	39,0	0,3	40,0	0,2	31,3	0,1	21,2	0,2	31,0	0,4	41,7	0,4	42,3	0,4	42,3	0,4	43,5	0,6	51,2	0,1	2,2																		
avril	0,4	39,8	0,4	39,9	0,4	41,5	1,0	100,0	0,3	36,4	0,3	35,5	0,2	32,1	0,1	23,1	0,2	28,6	0,3	35,2	0,3	35,5	0,3	36,3	0,4	42,2	0,1	1,6																				
mai	0,4	40,1	0,3	38,2	0,4	39,0	0,3	36,4	1,0	100,0	0,5	47,0	0,3	34,4	0,1	22,1	0,2	31,2	0,3	40,9	0,3	38,1	0,3	38,6	0,5	46,7	0,1	2,0																				
juin	0,3	40,4	0,3	37,6	0,3	40,0	0,3	35,5	0,5	47,0	1,0	100,0	0,3	36,4	0,1	23,2	0,2	31,9	0,4	43,6	0,4	40,2	0,3	38,7	0,5	48,3	0,1	2,4																				
juillet	0,2	32,8	0,2	31,4	0,2	31,3	0,2	32,1	0,3	34,4	0,3	36,4	1,0	100,0	0,1	28,0	0,2	31,5	0,3	34,2	0,2	32,9	0,2	33,5	0,3	35,0	0,1	1,3																				
août	0,1	21,7	0,1	20,8	0,1	21,2	0,1	23,1	0,1	22,1	0,1	23,2	0,1	28,0	1,0	100,0	0,1	22,5	0,1	22,0	0,1	22,7	0,1	22,0	0,1	22,8	0,1	1,2																				
septembre	0,2	31,7	0,2	31,1	0,2	31,0	0,2	28,6	0,2	31,2	0,2	31,9	0,2	31,5	0,1	22,5	1,0	100,0	0,3	36,3	0,2	35,6	0,2	37,0	0,3	36,7	0,1	1,5																				
octobre	0,4	45,8	0,4	41,3	0,4	41,7	0,3	35,2	0,3	40,9	0,4	43,6	0,3	34,2	0,1	22,0	0,3	36,3	1,0	100,0	0,5	50,0	0,4	45,0	0,5	53,8	0,1	3,1																				
novembre	0,4	45,5	0,4	41,5	0,4	42,3	0,3	35,5	0,3	38,1	0,4	40,2	0,2	32,9	0,1	22,7	0,2	35,6	0,5	50,0	1,0	100,0	0,5	51,7	0,5	49,3	0,1	2,4																				
décembre	0,5	47,7	0,4	44,4	0,4	43,5	0,3	36,3	0,3	38,6	0,3	38,7	0,2	33,5	0,1	22,0	0,2	37,0	0,4	44,9	0,5	51,7	1,0	100,0	0,5	48,5	0,1	2,0																				
2018	0,5	52,2	0,5	46,8	0,6	51,2	0,4	42,2	0,5	46,7	0,5	48,3	0,3	35,0	0,1	22,8	0,3	36,7	0,5	53,8	0,5	49,3	0,5	48,5	1,0	100,0	0,1	3,2																				
VT	0,1	2,2	0,1	1,8	0,1	2,2	0,1	1,6	0,2	2,0	0,1	2,4	0,1	1,3	0,1	1,0	0,1	1,5	0,1	3,1	0,1	2,4	0,1	2,0	0,2	3,2	1,0	100,0																				

k : nombre de classes. VT : vérité terrain.

TABLEAU D.3 – Coefficients Kappa (K) et F-Scores moyens (FS) obtenus au terme de la comparaison pixel à pixel de la classification de l'année complète 2018 et des onze fusions de classifications mensuelles de séries temporelles d'images optiques et radar Sentinel-1 L1/-2_L2A et de la VT avec la légende à 12 classes, de la zone d'intérêt T33PUL.

	bayes		bayesmarge		DSV2		HanV2		min		moy		moymarge		PCRV2		RF		SVM-lin_t0		SVM-rbf_t2		2018		VT				
	K	FS	K	FS	K	FS	K	FS	K	FS	K	FS	K	FS	K	FS	K	FS	K	FS	K	FS	K	FS	K	FS	K	FS	
L1-L2A																													
bayes	1,0	100,0	0,9	97,0	0,9	92,0	0,9	85,5	0,9	99,0	0,9	95,0	0,9	96,0	0,9	94,0	0,4	30,8	0,4	30,6	0,4	30,0	0,9	93,0	0,2	18,6	0,2	18,6	
bayesmarge	0,9	92,0	1,0	100,0	0,9	90,1	0,7	67,8	0,8	83,8	0,9	85,6	0,9	87,6	0,9	84,2	0,2	16,5	0,2	18,4	0,2	17,1	0,9	96,0	0,1	22,0	0,1	22,0	
DSV2	0,9	95,0	0,9	95,0	1,0	100,0	0,9	96,0	0,7	68,6	0,8	80,4	0,9	91,0	0,9	87,2	0,9	87,5	0,2	16,6	0,2	18,8	0,2	23,7	0,1	25,5	0,1	25,5	
HanV2	0,7	67,8	0,9	96,0	0,6	64,3	1,0	100,0	0,7	66,9	0,8	73,6	0,2	15,0	0,2	16,4	0,1	14,9	0,9	99,0	0,9	99,0	0,9	99,0	0,9	99,0	0,1	27,6	
min	0,8	83,8	0,8	80,4	0,6	64,3	0,9	96,0	1,0	100,0	0,8	73,0	0,8	76,0	0,2	14,5	0,2	16,7	0,1	15,1	0,9	94,0	0,9	95,0	0,1	31,6			
moy	0,9	99,0	0,9	85,6	0,9	91,0	0,7	69,1	0,8	73,9	1,0	100,0	0,9	91,2	0,9	87,0	0,2	17,1	0,2	19,2	0,2	17,8	0,9	96,0	0,1	27,7			
moymarge	0,9	94,0	0,9	98,0	0,9	87,6	0,9	87,2	0,7	66,9	0,8	73,0	1,0	100,0	0,9	96,0	0,9	84,3	0,2	17,3	0,2	19,2	0,2	18,2	0,1	29,3			
PCRV2	0,9	99,0	0,9	93,0	0,9	99,0	0,9	84,2	0,9	87,5	0,8	73,6	0,8	76,0	1,0	100,0	0,9	84,3	0,9	94,0	0,2	16,6	0,2	18,8	0,1	26,9			
RF	0,4	30,8	0,4	30,8	0,4	30,8	0,4	30,8	0,2	16,5	0,2	16,6	0,9	98,0	0,6	61,2	1,0	100,0	0,4	30,6	0,4	30,6	0,4	30,6	0,1	22,5			
SVM-lin_t0	0,2	18,4	0,2	18,8	0,2	16,4	0,2	16,7	0,2	19,2	0,2	19,2	0,2	18,8	0,6	61,2	0,9	99,0	1,0	100,0	0,8	55,1	0,8	55,1	0,1	21,6			
SVM-rbf_t2	0,8	55,1	0,2	17,1	0,2	17,2	0,1	14,9	0,1	15,1	0,2	17,8	0,2	18,2	0,2	17,1	0,6	64,4	0,8	78,3	1,0	100,0	0,5	27,9	0,1	22,0			
2018	0,4	28,3	0,5	24,5	0,5	23,9	0,5	29,4	0,5	29,5	0,3	29,3	0,1	25,6	0,3	29,6	0,5	27,8	0,5	27,9	0,1	22,0	1,0	100,0	0,1	22,0			
VT	0,2	18,6	0,1	22,0	0,1	25,5	0,1	27,6	0,1	31,6	0,1	27,7	0,1	29,3	0,1	26,9	0,1	22,5	0,1	21,6	0,1	22,0	0,1	22,0	1,0	100,0			

k : nombre de classes. VT : vérité terrain.

TABLE D.4 – Coefficients Kappa (K) et F-Scores moyens (FS) obtenus au terme de la comparaison pixel à pixel des classifications des synthèses mensuelles de périodes 45 et de leur synthèse fusion 2018_P45 de séries temporelles d'images optiques Sentinel-2_L3A et de la vérité terrain (VT) avec la légende à 5 classes, de la zone d'intérêt T33PUL.

	fév._P45		mar._P45		avr._P45		mai_P45		juin_P45		juil._P45		aoû._P45		sep._P45		oct._P45		nov._P45		2018_P45		VT	
L3A_P45	K	FS	K	FS	K	FS	K	FS	K	FS	K	FS	K	FS	K	FS	K	FS	K	FS	K	FS	K	FS
février_P45	1,0	100,0	0,5	56,7	0,4	49,6	0,3	47,9	0,4	45,7	0,4	44,9	0,2	33,8	0,3	45,1	0,4	51,3	0,4	53,9	0,5	58,3	0,6	39,6
mars_P45	0,5	56,7	1,0	100,0	0,4	49,1	0,3	42,8	0,3	41,3	0,3	40,0	0,1	30,6	0,3	40,4	0,3	44,4	0,3	44,3	0,4	49,9	0,3	37,0
avril_P45	0,4	49,6	0,4	49,1	1,0	100,0	0,3	44,3	0,3	40,3	0,3	40,7	0,2	31,8	0,3	38,9	0,3	41,8	0,3	44,3	0,4	48,7	0,3	37,7
mai_P45	0,3	47,9	0,3	42,8	0,3	44,3	1,0	100,0	0,4	52,6	0,3	45,2	0,2	32,5	0,3	43,7	0,3	46,8	0,4	49,7	0,4	52,7	0,3	38,3
juin_P45	0,4	45,7	0,3	41,3	0,3	40,3	0,4	52,6	1,0	100,0	0,4	50,6	0,2	31,5	0,3	42,3	0,4	48,3	0,4	47,1	0,4	47,4	0,2	29,9
juillet_P45	0,4	44,9	0,3	40,0	0,3	40,7	0,3	45,2	0,4	50,6	1,0	100,0	0,2	35,7	0,3	42,2	0,4	47,3	0,4	46,7	0,4	47,9	0,2	31,0
août_P45	0,2	33,8	0,1	30,6	0,2	31,8	0,2	32,5	0,2	31,5	0,2	35,7	1,0	100,0	0,2	32,8	0,2	33,8	0,2	34,5	0,2	35,8	0,1	27,1
septembre_P45	0,3	45,1	0,3	40,4	0,3	38,9	0,3	43,7	0,3	42,2	0,3	42,0	0,2	32,8	1,0	100,0	0,4	51,0	0,3	48,2	0,4	52,2	0,3	36,2
octobre_P45	0,4	51,3	0,3	44,4	0,3	41,8	0,3	46,8	0,4	48,3	0,4	47,3	0,2	33,8	0,4	51,0	1,0	100,0	0,5	63,9	0,5	60,0	0,2	36,2
novembre_P45	0,4	53,9	0,3	44,3	0,3	44,3	0,4	49,7	0,4	47,1	0,4	46,7	0,2	34,5	0,3	48,2	0,5	63,9	1,0	100,0	0,5	61,5	0,3	39,9
2018_P45	0,5	58,3	0,4	49,9	0,4	48,7	0,4	52,7	0,4	47,4	0,4	47,9	0,2	35,8	0,4	52,2	0,5	59,9	0,5	61,5	1,0	100,0	0,5	50,1
VT	0,3	39,6	0,3	37,0	0,3	37,7	0,3	38,3	0,2	29,9	0,2	31,0	0,1	27,1	0,3	36,2	0,2	36,2	0,3	39,9	0,5	50,1	1,0	100,0

k : nombre de classes. VT : vérité terrain.

TAB. D.5 – Coefficients Kappa (K) et F-Scores moyens (FS) après comparaison pixel à pixel des classifications des synthèses de période 105 jours et de la VT avec 5 classes.

	mar._P105		mai_P105		juil._P105		sep._P105		nov._P105		2018_P105		VT	
<i>k</i> = 5														
L3A_P105	K	FS	K	FS	K	FS	K	FS	K	FS	K	FS	K	FS
mars_P105	1,0	100,0	0,3	46,6	0,3	40,2	0,4	48,7	0,5	52,8	0,5	54,2	0,3	38,9
mai_P105	0,3	46,6	1,0	100,0	0,3	45,1	0,4	48,2	0,4	48,8	0,4	51,3	0,3	38,3
juillet_P105	0,3	40,2	0,3	45,1	1,0	100,0	0,3	45,7	0,3	45,1	0,3	45,4	0,2	28,0
septembre_P105	0,4	48,7	0,4	48,2	0,3	45,7	1,0	100,0	0,6	65,3	0,5	62,0	0,3	37,4
novembre_P105	0,5	52,8	0,4	48,8	0,3	45,1	0,6	65,3	1,0	100,0	0,5	62,8	0,3	37,3
2018_P105	0,5	54,2	0,4	51,2	0,3	45,4	0,5	62,0	0,5	62,8	1,0	100,0	0,4	47,9
VT	0,3	38,9	0,3	38,3	0,2	28,0	0,3	37,4	0,3	37,3	0,4	47,9	1,0	100,0

TAB. D.6 – Coefficients Kappa (K) et F-Scores moyens (FS) après comparaison pixel à pixel des classifications des synthèses de période 165 jours et de la VT avec 5 classes.

	avr._P165		juil._P165		oct._P165		2018_P165		VT	
<i>k</i> = 5										
L3A_P165	K	FS	K	FS	K	FS	K	FS	K	FS
avril_P165	1,0	100,0	0,4	51,2	0,4	53,3	0,5	55,9	0,3	38,9
juillet_P165	0,4	51,2	1,0	100,0	0,4	56,2	0,5	59,4	0,3	37,6
octobre_P165	0,4	53,3	0,4	56,6	1,0	100,0	0,6	67,4	0,3	41,4
2018_P165	0,5	55,9	0,5	59,4	0,6	67,4	1,0	100,0	0,4	42,2
VT	0,3	38,9	0,3	37,6	0,3	41,4	0,4	44,2	1,0	100,0

k : nombre de classes. VT : vérité terrain.

D.1.2.1.2 En présence d'images Sentinel-1

Classifications

Le Tableau D.13 présente les différentes valeurs du coefficient Kappa (K) et du F-Score moyen (FS) obtenues au terme de la comparaison pixel à pixel des classifications de séries temporelles d'images optiques et radar Sentinel-1_L1/-2_L2A des douze mois et de l'année complète 2018 et de la VT en utilisant la légende à 12 classes, de la zone d'intérêt T32NPL.

Fusions de classifications

Le Tableau D.14 présente les différentes valeurs du coefficient Kappa (K) et du F-Score moyen (FS) obtenues au terme de la comparaison pixel à pixel de la classification de l'année complète 2018 et des onze fusions de classifications mensuelles, de séries temporelles d'images optiques et radar Sentinel-1_L1/-2_L2A et de la VT en utilisant la légende à 12 classe, de la zone d'intérêt T32NPL.

D.1.2.2 Sensibilité aux périodes de synthèse mensuelle de séries temporelles d'images Sentinel-2

D.1.2.2.1 En absence d'images Sentinel-1

Classifications

5 classes Les Tableaux D.15, D.16 et D.17 présentent les différentes valeurs du coefficient Kappa (K) et du F-Score moyen (FS) obtenues au terme de la comparaison pixel à pixel des classifications des

TAB. D.7 – Coefficients Kappa (K) et F-Scores moyens (FS) obtenus par comparaison pixel à pixel des classifications des synthèses mensuelles de périodes 45 et de leur synthèse fusion 2018_P45 de séries temporelles d'images optiques et radar Sentinel-1_L1/-2_L3A et de la vérité terrain (VT) avec la légende à 5 classes, de la zone d'intérêt T33PUL.

	fév._P45		mar._P45		avr._P45		mai_P45		juin_P45		juil._P45		aoû._P45		sep._P45		oct._P45		nov._P45		2018_P45		VT			
<i>k</i> = 5	K	FS	K	FS	K	FS	K	FS	K	FS	K	FS	K	FS	K	FS	K	FS	K	FS	K	FS	K	FS		
L1-L3A_P45																										
février_P45	1,0	100,0	0,5	55,5	0,4	50,1	0,4	49,1	0,4	50,1	0,3	43,3	0,2	32,2	0,3	46,8	0,4	49,7	0,4	49,7	0,4	55,0	0,4	55,4	0,5	55,5
mars_P45	0,5	55,5	1,0	100,0	0,4	49,2	0,3	42,6	0,3	42,1	0,3	40,6	0,1	30,5	0,3	41,0	0,3	44,3	0,4	45,7	0,4	45,7	0,4	50,4	0,4	50,1
avril_P45	0,4	50,1	0,4	49,2	1,0	100,0	0,3	44,7	0,3	44,6	0,3	40,1	0,2	30,8	0,3	40,8	0,3	41,9	0,4	45,3	0,4	45,3	0,4	48,2	0,4	49,1
mai_P45	0,4	49,1	0,3	42,6	0,3	44,7	1,0	100,0	0,5	58,4	0,3	45,2	0,2	30,3	0,3	44,8	0,4	47,1	0,4	50,1	0,3	47,7	0,4	50,1	0,4	50,1
juin_P45	0,4	50,1	0,3	42,1	0,3	44,6	0,5	58,4	1,0	100,0	0,4	50,5	0,2	32,2	0,3	45,6	0,4	48,5	0,4	51,6	0,4	51,6	0,4	51,0	0,3	43,3
juillet_P45	0,3	43,3	0,3	40,6	0,3	40,1	0,3	45,2	0,4	50,5	1,0	100,0	0,2	35,9	0,3	42,5	0,4	46,8	0,4	46,3	0,4	46,3	0,4	48,1	0,2	32,2
août_P45	0,2	32,2	0,1	30,5	0,2	30,8	0,2	30,3	0,2	32,2	0,2	35,9	1,0	100,0	0,2	32,2	0,2	31,8	0,2	32,1	0,2	32,1	0,2	33,5	0,3	46,8
septembre_P45	0,3	46,8	0,3	41,0	0,3	40,8	0,3	44,8	0,3	45,6	0,3	42,5	0,2	32,2	1,0	100,0	0,4	51,1	0,4	50,3	0,4	50,3	0,4	51,8	0,4	49,7
octobre_P45	0,4	49,7	0,3	44,3	0,3	41,9	0,4	47,0	0,4	48,5	0,4	46,8	0,2	31,8	0,4	51,1	1,0	100,0	0,6	65,6	0,5	59,4	0,5	59,4	0,4	55,0
novembre_P45	0,4	55,0	0,4	45,7	0,4	45,3	0,4	50,1	0,4	51,6	0,4	46,3	0,2	32,1	0,4	50,3	0,6	65,6	1,0	100,0	0,5	59,2	1,0	100,0	0,5	50,1
2018_P45	0,4	55,4	0,4	50,4	0,4	48,2	0,3	47,7	0,4	51,0	0,4	48,1	0,2	33,5	0,4	51,8	0,5	59,4	0,5	59,2	1,0	100,0	0,5	59,2	0,5	50,1
VT	0,4	40,6	0,4	38,0	0,4	38,7	0,4	39,3	0,3	30,9	0,3	32,0	0,2	28,1	0,4	37,2	0,3	37,2	0,4	40,9	0,6	51,1	1,0	100,0	0,5	50,1

k : nombre de classes. VT : vérité terrain.

TAB. D.8 – Coefficients Kappa (K) et F-Scores moyens (FS) après comparaison pixel à pixel des classifications des synthèses de période 105 jours et de la VT avec 5 classes.

	mar._P105		mai_P105		juil._P105		sep._P105		nov._P105		2018_P105		VT	
<i>k</i> = 5														
L1-L3A_P105	K	FS	K	FS	K	FS	K	FS	K	FS	K	FS	K	FS
mars_P105	1,0	100,0	0,4	51,4	0,3	40,7	0,4	47,4	0,4	53,0	0,5	54,9	0,4	51,4
mai_P105	0,4	51,4	1,0	100,0	0,4	44,2	0,3	44,9	0,4	50,0	0,5	50,5	0,3	40,7
juillet_P105	0,3	40,7	0,4	44,2	1,0	100,0	0,4	47,0	0,4	45,4	0,4	49,8	0,4	47,4
septembre_P105	0,4	47,4	0,3	44,9	0,4	47,0	1,0	100,0	0,6	64,0	0,5	63,0	0,4	53,1
novembre_P105	0,4	53,1	0,4	50,0	0,4	45,4	0,6	64,0	1,0	100,0	0,6	62,6	0,5	54,9
2018_P105	0,5	54,9	0,5	50,5	0,4	49,7	0,5	63,0	0,6	62,6	1,0	100,0	0,5	48,9
VT	0,4	39,9	0,4	39,3	0,3	29,0	0,4	38,4	0,4	38,3	0,5	48,9	1,0	100,0

TAB. D.9 – Coefficients Kappa (K) et F-Scores moyens (FS) après comparaison pixel à pixel des classifications des synthèses de période 165 jours et de la VT avec 5 classes.

	avr._P165		juil._P165		oct._P165		2018_P165		VT	
<i>k</i> = 5										
L1-L3A_P165	K	FS	K	FS	K	FS	K	FS	K	FS
avril_P165	1,0	100,0	0,4	48,4	0,4	48,4	0,4	50,9	0,4	48,4
juillet_P165	0,4	48,4	1,0	100,0	0,4	54,0	0,5	60,0	0,4	48,4
octobre_P165	0,4	48,4	0,4	54,0	1,0	100,0	0,5	62,9	0,4	50,9
2018_P165	0,4	50,9	0,5	60,0	0,5	62,9	1,0	100,0	0,5	43,2
VT	0,4	39,9	0,4	38,6	0,4	42,4	0,5	45,2	1,0	100,0

k : nombre de classes. VT : vérité terrain.

différentes synthèses mensuelles de périodes 45, 105 et 165 et de leurs synthèses fusions respectives 2018_P45, 2018_P105 et 2018_P165 de séries temporelles d'images optiques Sentinel-2_L3A et de la vérité terrain (VT) avec la légende à 5 classes, de la zone d'intérêt T32NPL.

D.1.2.2.2 En présence d'images Sentinel-1

Classifications

5 classes Les Tableaux D.18, D.19 et D.20 présentent les différentes valeurs du coefficient Kappa (K) et du F-Score moyen (FS) obtenues au terme de la comparaison pixel à pixel des classifications des différentes synthèses mensuelles de périodes 45, 105 et 165 et de leurs synthèses fusions respectives 2018_P45, 2018_P105 et 2018_P165 de séries temporelles d'images optiques et radar Sentinel-1_L1/-2_L3A et de la vérité terrain (VT) avec la légende à 5 classes, de la zone d'intérêt T32NPL.

Fusions de classifications

5 classes Les Tableaux D.21 et D.22 présentent les différentes valeurs du coefficient Kappa (K) et du F-Score moyen (FS) obtenues au terme de la comparaison pixel à pixel respectivement des classifications des synthèses 2018_P45 et 2018_P315 ainsi que des onze fusions de classifications des synthèses mensuelles de période 45 jours de séries temporelles d'images optiques et radar Sentinel-1_L1/-2_L3A et de la vérité terrain (VT) avec la légende à 5 classes, de la zone d'intérêt T32NPL.

TAB. D.10 – Coefficients Kappa (K) et F-Scores moyens (FS) obtenus par comparaison pixel à pixel de la classification de la synthèse 2018_P45 ainsi que des onze fusions de classifications des synthèses mensuelles de période 45 jours de séries temporelles d'images optiques et radar Sentinel-1_L1/-2_L3A et de la vérité terrain (VT) avec la légende à 5 classes, de la zone d'intérêt T33PULL.

	baves		bayesmarge		DSV2		HanV2		min		moy		moymarge		PCRV2		RF		SVM-lin_t0		SVM-rbf_t2		2018_P45		VT					
	K	FS	K	FS	K	FS	K	FS	K	FS	K	FS	K	FS	K	FS	K	FS	K	FS	K	FS	K	FS	K	FS	K	FS		
<i>L1-L3A_P45</i>																														
baves	1,0	100,0	0,9	95,0	0,9	90,0	0,9	98,0	0,9	99,5	0,9	97,0	0,9	99,0	0,9	97,0	0,9	98,0	0,9	99,4	0,9	98,0	0,9	97,0	0,9	98,0	0,9	97,0	0,9	99,0
bayesmarge	0,9	96,0	1,0	100,0	0,9	94,0	0,9	91,8	0,7	78,1	0,8	83,3	0,9	91,7	0,9	91,9	0,9	89,6	0,8	83,3	0,8	79,9	0,9	87,8	0,9	92,0	0,9	92,0	0,9	92,0
DSV2	0,9	96,0	0,9	97,0	1,0	100,0	0,9	95,0	0,8	80,0	0,8	84,5	0,9	94,5	0,9	88,0	0,9	91,7	0,8	84,0	0,8	80,5	0,9	90,2	0,9	97,9	0,9	97,9	0,9	97,9
HanV2	0,7	78,1	0,8	80,0	0,9	96,0	1,0	100,0	0,8	81,0	0,7	77,8	0,8	85,1	0,7	79,3	0,7	74,9	0,8	81,6	0,9	99,5	0,8	83,3	0,8	84,5	0,8	84,5	0,8	84,5
min	0,7	71,8	0,9	97,0	0,8	80,2	0,7	76,4	1,0	100,0	0,9	91,0	0,9	94,0	0,9	97,0	0,9	95,0	0,9	91,7	0,9	94,5	0,8	81,0	0,8	80,2	0,8	80,2	0,8	80,2
moy	0,9	96,0	0,9	90,8	0,9	92,6	0,8	85,7	0,8	81,4	1,0	100,0	0,9	97,0	0,9	99,0	0,9	97,0	0,9	98,0	0,9	91,9	0,9	89,0	0,7	77,8	0,9	91,7	0,9	91,7
moymarge	0,7	76,4	0,9	90,8	0,9	97,0	0,9	89,0	0,8	83,6	0,8	79,7	1,0	100,0	0,9	99,0	0,9	97,0	0,9	92,0	0,9	94,0	0,9	89,6	0,9	91,7	0,9	91,7	0,9	91,7
PCRV2	0,8	85,1	0,8	79,7	0,9	92,6	0,9	89,0	0,9	95,0	0,9	88,8	0,8	80,8	1,0	100,0	0,9	98,0	0,9	97,0	0,9	94,0	0,9	95,0	0,8	83,3	0,9	91,7	0,9	91,7
RF	0,8	84,0	0,7	79,3	0,7	74,3	0,8	85,7	0,8	83,6	0,8	85,1	0,9	95,0	0,8	84,5	1,0	100,0	0,9	99,4	0,9	99,4	0,9	99,4	0,9	99,4	0,9	99,4	0,9	99,4
SVM-lin_t0	0,8	80,0	0,8	80,5	0,7	74,9	0,7	72,7	0,8	81,4	0,8	79,7	0,8	80,8	0,8	84,5	0,9	99,0	1,0	100,0	0,9	98,0	0,9	97,0	0,8	86,0	0,9	99,4	0,9	99,4
SVM-rbf_t2	0,9	99,0	0,9	95,0	0,9	96,0	0,9	97,0	0,9	87,8	0,9	90,2	0,8	81,6	0,8	79,7	0,9	90,5	0,9	86,2	1,0	100,0	0,9	88,0	0,8	86,0	0,9	99,4	0,9	99,4
2018_P45	0,9	92,0	0,9	95,0	0,9	95,0	0,9	94,0	0,9	96,0	0,9	97,0	0,9	96,0	0,9	99,0	0,9	95,0	0,9	92,0	0,9	98,0	1,0	100,0	0,9	94,0	0,9	94,0	0,9	94,0
VT	0,9	82,0	0,8	85,0	0,9	92,0	0,9	95,0	0,7	75,0	0,7	72,0	0,8	83,0	0,7	71,0	0,8	82,0	0,7	74,0	0,7	78,0	0,7	74,0	1,0	100,0	0,7	74,0	1,0	100,0

k : nombre de classes. VT : vérité terrain.

TAB. D.11 – Coefficients Kappa (K) et F-Scores moyens (FS) obtenus par comparaison pixel à pixel de la classification de la synthèse mensuelle 2018_P315 ainsi que des onze fusions de classifications de synthèses mensuelles de période 45 jours de séries temporelles d'images optiques et radar Sentinel-1_L1/-2_L3A et de la vérité terrain (VT) avec la légende à 5 classes, de la zone d'intérêt T33PUL.

	baves		bayesmarge		DSV2		HanV2		min		moy		moymarge		PCRv2		RF		SVM-lin_t0		SVM-rbf_t2		juin_P315		VT					
	K	FS	K	FS	K	FS	K	FS	K	FS	K	FS	K	FS	K	FS	K	FS	K	FS	K	FS	K	FS	K	FS				
<i>L1-L3A_P315</i>																														
baves	1,0	100,0	0,9	98,4	0,9	97,0	0,9	94,0	0,9	96,6	0,9	99,0	0,9	97,8	0,9	99,4	0,7	76,2	0,9	90,4	0,5	57,6	0,9	98,4	0,9	98,4	0,9	98,4		
bayesmarge	0,9	98,4	1,0	100,0	0,9	98,4	0,9	97,0	0,9	98,2	0,9	98,3	0,9	95,1	0,9	98,9	0,9	99,4	0,9	98,3	0,7	76,5	0,9	90,1	0,5	57,8	0,9	90,1	0,5	57,8
DSV2	0,9	99,7	0,9	99,7	1,0	100,0	0,9	99,7	0,9	98,2	0,9	98,0	0,9	99,5	0,9	96,8	0,9	98,8	0,9	97,6	0,9	99,3	0,7	76,2	0,9	90,3	0,7	76,2	0,9	90,3
HanV2	0,5	57,6	0,9	98,0	0,9	97,0	1,0	100,0	0,9	97,0	0,9	98,3	0,9	99,5	0,9	99,0	0,9	96,6	0,9	98,9	0,9	97,7	0,9	99,3	0,7	76,3	0,9	99,3	0,7	76,3
min	0,9	90,4	0,5	57,6	0,9	96,6	0,9	96,6	1,0	100,0	0,9	96,6	0,9	95,1	0,9	96,8	0,9	98,0	0,9	95,6	0,9	94,5	0,9	96,2	0,7	75,7	0,9	96,2	0,7	75,7
moy	0,9	89,9	0,5	57,4	0,9	99,0	0,9	98,9	0,9	98,8	1,0	100,0	0,9	95,6	0,9	97,0	0,9	98,7	0,9	99,0	0,7	76,4	0,9	90,4	0,5	57,7	0,9	90,4	0,5	57,7
moymarge	0,9	97,8	0,9	97,8	0,9	97,8	0,9	97,8	0,9	99,4	0,9	97,6	1,0	100,0	0,9	94,5	0,9	98,7	0,9	98,0	0,9	97,8	0,7	76,6	0,9	90,0	0,7	76,6	0,9	90,0
PCRv2	0,5	57,9	0,9	96,0	0,9	98,0	0,9	98,0	0,9	97,0	0,9	98,3	0,9	99,3	1,0	100,0	0,9	96,2	0,9	99,0	0,9	97,8	0,9	98,2	0,7	76,3	0,9	98,2	0,7	76,3
RF	0,9	90,5	0,5	57,6	0,7	76,2	0,7	76,2	0,7	76,2	0,7	76,2	0,7	76,5	0,7	76,2	1,0	100,0	0,7	75,7	0,7	76,4	0,7	76,6	0,7	76,6	0,7	76,6	0,7	76,6
SVM-lin_t0	0,9	98,0	0,7	75,3	0,6	64,1	0,9	90,4	0,9	90,4	0,9	90,4	0,9	90,4	0,9	90,1	0,9	90,3	1,0	100,0	0,9	90,0	0,9	90,4	0,9	90,4	0,9	90,4	0,9	90,0
SVM-rbf_t2	0,9	90,5	0,7	75,3	0,9	97,0	0,5	58,3	0,5	57,6	0,5	57,6	0,5	57,6	0,5	57,6	0,5	57,8	0,5	57,6	1,0	100,0	0,5	57,4	0,5	57,4	0,5	57,4	0,5	57,7
2018_P315	0,5	57,9	0,5	57,6	0,6	64,1	0,5	58,3	0,9	98,0	0,9	99,0	0,9	97,0	0,9	96,0	0,9	97,0	0,9	98,0	0,9	99,0	1,0	100,0	0,9	97,0	0,9	97,0	0,9	97,0
VT	0,5	58,0	0,7	76,0	0,8	88,0	0,8	85,0	0,9	95,0	0,7	77,0	0,6	64,0	0,7	77,0	0,8	88,0	0,8	82,0	0,6	66,0	0,8	84,0	0,8	84,0	0,8	84,0	0,8	84,0

k : nombre de classes. VT : vérité terrain.

TAB. D.12 – Coefficients Kappa (K) et F-Scores moyens (FS) obtenus au terme de la comparaison pixel à pixel des classifications de séries temporelles d'images optiques Sentinel-2_L2A des douze mois et de l'année complète 2018 et de la VT avec la légende à 12 classes, de la zone d'intérêt T32NPL.

	jan.		fév.		mar.		avr.		mai		juin		juil.		août.		sep.		oct.		nov.		déc.		2018		VT					
<i>k</i> = 12	K	FS	K	FS	K	FS	K	FS	K	FS	K	FS	K	FS	K	FS	K	FS	K	FS	K	FS	K	FS	K	FS	K	FS	K	FS		
L2A																																
janvier	1,0	100,0	0,4	43,0	0,2	30,0	0,1	15,5	0,2	23,5	0,2	25,0	0,2	21,9	0,1	12,8	0,2	22,9	0,1	17,0	0,3	32,4	0,4	38,5	0,5	44,7	0,3	30,9				
février	0,4	43,0	1,0	100,0	0,3	30,3	0,1	15,5	0,2	23,8	0,2	24,5	0,2	22,6	0,1	13,1	0,2	22,8	0,1	16,7	0,3	32,2	0,4	36,2	0,5	46,0	0,3	32,0				
mars	0,2	30,0	0,3	30,3	1,0	100,0	0,1	15,1	0,2	22,0	0,2	22,7	0,2	21,4	0,1	12,5	0,1	19,5	0,1	14,9	0,2	26,8	0,2	28,3	0,3	35,0	0,2	24,6				
avril	0,1	15,5	0,1	15,5	0,1	15,1	1,0	100,0	0,1	13,8	0,1	14,4	0,1	17,2	0,1	12,7	0,1	12,7	0,1	9,9	0,1	14,8	0,1	15,2	0,1	17,4	0,1	12,3				
mai	0,2	23,5	0,2	23,8	0,2	22,0	0,1	13,8	1,0	100,0	0,2	22,1	0,2	20,1	0,1	12,4	0,1	19,8	0,1	13,0	0,2	23,1	0,2	23,9	0,3	27,8	0,2	20,4				
juin	0,2	25,0	0,2	24,5	0,2	22,7	0,1	14,4	0,2	22,1	1,0	100,0	0,2	23,0	0,1	12,3	0,1	19,7	0,1	14,0	0,2	24,0	0,2	26,4	0,3	29,5	0,2	21,5				
juillet	0,2	21,9	0,2	22,6	0,2	21,4	0,1	17,2	0,2	20,1	0,2	23,0	1,0	100,0	0,1	16,1	0,1	18,7	0,1	13,1	0,2	22,3	0,2	22,4	0,2	27,2	0,1	18,6				
août	0,1	12,8	0,1	13,1	0,1	12,5	0,1	12,7	0,1	12,4	0,1	12,3	0,1	16,1	1,0	100,0	0,1	12,7	0,1	9,5	0,1	13,1	0,1	12,9	0,1	15,4	0,1	12,5				
septembre	0,2	22,9	0,2	22,8	0,1	19,5	0,1	12,7	0,1	19,8	0,1	19,7	0,1	18,7	0,1	12,7	1,0	100,0	0,1	13,9	0,2	23,0	0,2	23,6	0,3	26,9	0,2	20,8				
octobre	0,1	17,0	0,1	16,7	0,1	14,9	0,1	9,9	0,1	13,0	0,1	14,0	0,1	13,0	0,1	9,5	0,1	13,9	1,0	100,0	0,1	17,0	0,1	16,8	0,1	19,1	0,1	16,2				
novembre	0,3	32,4	0,3	32,2	0,2	26,8	0,1	14,8	0,2	23,1	0,2	24,0	0,2	22,3	0,1	13,1	0,2	23,0	0,1	17,0	1,0	100,0	0,3	35,6	0,4	37,2	0,2	24,9				
décembre	0,4	38,5	0,4	36,2	0,2	28,3	0,1	15,2	0,2	23,9	0,2	26,4	0,2	22,4	0,1	12,9	0,2	23,6	0,1	16,8	0,3	35,6	1,0	100,0	0,4	40,7	0,2	27,0				
2018	0,5	44,7	0,5	46,0	0,3	35,0	0,1	17,4	0,3	27,8	0,3	29,5	0,2	27,2	0,1	15,4	0,3	26,9	0,1	19,1	0,4	37,2	0,4	40,7	1,0	100,0	0,3	41,9				
VT	0,3	30,9	0,3	32,0	0,2	24,6	0,1	12,3	0,2	20,4	0,2	21,5	0,1	18,6	0,1	12,5	0,2	20,8	0,1	16,2	0,2	24,9	0,2	27,0	0,3	41,9	1,0	100,0				

k : nombre de classes. VT : vérité terrain.

TABLEAU D.13 – Coefficients Kappa (K) et F-Scores moyens (FS) obtenus au terme de la comparaison pixel à pixel des classifications de séries temporelles d'images optiques et radar Sentinel-1 L1/-2_L2A des douze mois et de l'année complète 2018 et de la VT avec la légende à 12 classes, de la zone d'intérêt T32NPL.

	jan.	fév.	mar.	avr.	mai	juin	juil.	août.	sep.	oct.	nov.	déc.	2018	VT
<i>k = 12</i>														
L1-L2A	K FS													
janvier	1,0 100,0	0,5 43,2	0,3 31,2	0,1 16,1	0,2 24,4	0,2 24,6	0,2 22,0	0,1 13,0	0,2 23,1	0,1 16,7	0,3 33,1	0,3 36,9	0,5 46,3	0,3 30,8
février	0,5 43,2	1,0 100,0	0,3 32,3	0,1 16,3	0,2 24,7	0,2 24,7	0,2 23,0	0,1 13,2	0,2 23,0	0,1 16,7	0,4 33,1	0,3 35,6	0,5 44,9	0,3 30,0
mars	0,3 31,2	0,3 32,3	1,0 100,0	0,1 14,8	0,2 22,9	0,2 23,1	0,1 21,5	0,1 12,4	0,2 21,6	0,1 15,0	0,2 27,4	0,3 29,6	0,3 36,7	0,2 24,7
avril	0,1 16,1	0,1 16,3	0,1 14,8	1,0 100,0	0,1 14,0	0,1 14,2	0,1 17,4	0,1 12,6	0,1 12,9	0,1 9,6	0,1 15,0	0,1 14,9	0,1 18,2	0,1 14,0
mai	0,2 24,4	0,2 24,7	0,2 22,9	0,1 14,0	1,0 100,0	0,2 22,1	0,2 20,1	0,1 12,4	0,2 19,8	0,1 12,9	0,2 23,2	0,2 23,9	0,3 28,4	0,2 22,1
juin	0,2 24,6	0,2 24,7	0,2 23,1	0,1 14,2	0,2 22,1	1,0 100,0	0,2 22,5	0,1 12,4	0,1 19,1	0,1 13,8	0,2 23,6	0,2 24,2	0,3 29,1	0,2 21,4
juillet	0,2 22,0	0,2 23,0	0,1 21,2	0,1 17,4	0,2 20,1	0,2 22,5	1,0 100,0	0,1 15,8	0,1 19,0	0,1 12,9	0,2 21,8	0,2 22,0	0,2 26,7	0,1 19,0
août	0,1 13,0	0,1 13,2	0,1 12,4	0,1 12,6	0,1 12,4	0,1 12,4	0,1 15,8	1,0 100,0	0,1 12,7	0,1 9,2	0,1 12,9	0,1 13,0	0,1 15,1	0,1 13,6
septembre	0,2 23,1	0,2 23,0	0,2 21,6	0,1 12,9	0,2 19,8	0,1 19,1	0,1 19,0	0,1 12,7	1,0 100,0	0,1 13,7	0,2 23,0	0,2 24,0	0,3 27,0	0,2 20,6
octobre	0,1 16,7	0,1 16,7	0,1 15,0	0,1 9,6	0,1 12,9	0,1 13,8	0,1 12,9	0,1 9,2	0,1 13,7	1,0 100,0	0,1 16,6	0,1 16,4	0,1 18,9	0,1 16,4
novembre	0,3 33,1	0,4 33,1	0,2 27,4	0,1 15,0	0,2 23,2	0,2 23,6	0,2 21,8	0,1 12,9	0,2 23,0	0,1 16,6	1,0 100,0	0,3 35,0	0,4 37,8	0,2 24,8
décembre	0,3 36,9	0,3 35,6	0,3 29,6	0,1 14,9	0,2 23,9	0,2 24,2	0,2 22,0	0,1 13,0	0,2 24,0	0,1 16,4	0,3 35,0	1,0 100,0	0,4 40,3	0,2 27,1
2018	0,5 46,3	0,5 44,9	0,3 36,7	0,1 18,2	0,3 28,4	0,3 29,1	0,2 26,7	0,1 15,1	0,3 27,0	0,1 18,9	0,4 37,8	0,4 40,3	1,0 100,0	0,3 39,7
VT	0,3 30,8	0,3 30,0	0,2 24,7	0,1 14,0	0,2 22,1	0,2 21,4	0,1 19,0	0,1 13,6	0,2 20,6	0,1 16,4	0,2 24,8	0,2 27,1	0,3 39,7	1,0 100,0

k : nombre de classes. VT : vérité terrain.

TAB. D.14 – Coefficients Kappa (K) et F-Scores moyens (FS) obtenus au terme de la comparaison pixel à pixel de la classification de l'année complète 2018 et des onze fusions de classifications mensuelles, de séries temporelles d'images optiques et radar Sentinel-1_L1/-2_L2A et de la VT avec la légende à 12 classes, de la zone d'intérêt T32NPL.

	bayes		bayesmarge		DSV2		HanV2		min		moy		moymarge		PCRV2		RF		SVM-lin_t0		SVM-rbf_t2		2018		VT					
	K	FS	K	FS	K	FS	K	FS	K	FS	K	FS	K	FS	K	FS	K	FS	K	FS	K	FS	K	FS	K	FS	K	FS		
L1-L2A																														
bayes	1,0	100,0	0,9	95,0	0,9	98,0	0,9	81,2	0,9	97,1	0,9	98,0	0,9	97,0	0,9	96,0	0,9	86,5	0,9	84,1	0,9	89,6	0,9	77,7	0,7	59,8	0,9	89,6		
bayesmarge	0,9	97,0	1,0	100,0	0,8	72,6	0,6	50,4	0,5	53,2	0,9	72,7	0,9	69,8	0,8	69,8	0,7	53,2	0,6	49,6	0,7	54,7	0,6	53,4	0,3	31,9	0,7	54,7	0,6	53,4
DSV2	0,9	94,0	0,8	72,6	1,0	100,0	0,6	51,0	0,5	53,6	0,9	74,6	0,8	64,5	0,9	78,7	0,7	50,1	0,6	46,2	0,7	51,4	0,6	50,2	0,3	36,1	0,7	51,4	0,6	50,2
HanV2	0,9	81,2	0,6	50,4	0,6	51,0	1,0	100,0	0,4	41,3	0,6	55,6	0,5	44,2	0,6	58,1	0,5	41,7	0,4	40,3	0,5	43,1	0,5	44,0	0,3	32,2	0,5	43,1	0,5	44,0
min	0,9	97,1	0,5	53,2	0,5	53,6	0,4	41,3	1,0	100,0	0,5	45,7	0,4	39,6	0,5	48,3	0,4	34,9	0,4	35,4	0,4	36,3	0,4	39,6	0,2	28,1	0,4	36,3	0,4	39,6
moy	0,9	96,0	0,9	72,7	0,9	74,6	0,6	55,2	0,5	45,7	1,0	100,0	0,8	65,7	0,8	82,6	0,7	56,5	0,6	51,9	0,7	58,9	0,6	58,6	0,3	38,6	0,7	58,9	0,6	58,6
moymarge	0,9	93,0	0,9	69,8	0,8	64,5	0,5	44,2	0,4	39,6	0,8	65,7	1,0	100,0	0,7	60,0	0,7	53,2	0,6	49,9	0,7	56,6	0,6	49,9	0,3	34,4	0,7	56,6	0,6	49,9
PCRV2	0,9	94,0	0,8	69,8	0,9	78,7	0,6	58,1	0,5	48,3	0,8	82,6	0,7	60,0	1,0	100,0	0,7	53,2	0,6	48,9	0,7	54,7	0,6	55,3	0,3	37,1	0,7	54,7	0,6	55,3
RF	0,9	86,5	0,7	53,2	0,7	50,1	0,5	41,7	0,4	34,9	0,7	56,5	0,7	53,2	0,7	53,2	1,0	100,0	0,6	57,5	0,7	65,4	0,5	47,3	0,3	32,7	0,7	65,4	0,6	51,1
SVM-lin_t0	0,9	84,1	0,6	49,6	0,6	46,2	0,4	40,3	0,4	35,4	0,6	51,9	0,6	49,9	0,6	48,9	0,6	57,5	1,0	100,0	0,7	70,6	0,5	47,3	0,3	35,3	0,7	70,6	0,5	47,3
SVM-rbf_t2	0,9	89,6	0,7	54,7	0,7	51,4	0,5	43,1	0,4	36,3	0,7	58,9	0,7	56,6	0,7	54,7	0,7	65,4	0,7	70,6	1,0	100,0	0,6	53,2	0,3	38,1	1,0	100,0	0,6	53,2
2018	0,9	77,7	0,6	53,4	0,6	50,2	0,5	44,0	0,4	39,6	0,6	58,6	0,6	50,0	0,6	55,3	0,6	51,2	0,5	47,3	0,6	53,2	1,0	100,0	0,3	39,7	0,6	53,2	1,0	100,0
VT	0,7	59,8	0,3	31,9	0,3	36,1	0,3	32,2	0,2	28,1	0,3	38,6	0,3	34,4	0,3	37,1	0,3	32,7	0,3	35,3	0,3	38,1	0,3	39,7	1,0	100,0	0,3	38,1	0,3	39,7

k : nombre de classes. VT : vérité terrain.

TABLEAU D.15 – Coefficients Kappa (K) et F-Scores moyens (FS) obtenus au terme de la comparaison pixel à pixel des classifications des synthèses mensuelles de périodes 45 et de leur synthèse fusion 2018_P45 de séries temporelles d'images optiques Sentinel-2_L3A et de la vérité terrain (VT) avec la légende à 5 classes, de la zone d'intérêt T32NPL.

	fév._P45		mar._P45		avr._P45		mai_P45		juin_P45		juil._P45		aoû._P45		sep._P45		oct._P45		nov._P45		2018_P45		VT	
L3A_P45	K	FS	K	FS	K	FS	K	FS	K	FS	K	FS	K	FS	K	FS	K	FS	K	FS	K	FS	K	FS
février_P45	1,0	100,0	0,5	53,6	0,4	45,9	0,4	38,5	0,5	45,9	0,4	45,1	0,1	28,1	0,4	41,7	0,4	41,3	0,5	53,1	0,6	59,8	0,4	37,1
mars_P45	0,5	53,6	1,0	100,0	0,4	47,2	0,3	38,3	0,4	45,8	0,4	44,2	0,1	28,2	0,3	39,8	0,3	38,1	0,4	47,2	0,5	56,7	0,3	33,9
avril_P45	0,4	45,9	0,4	47,2	1,0	100,0	0,3	42,8	0,4	43,0	0,4	42,7	0,1	27,3	0,3	38,2	0,3	36,0	0,4	43,4	0,4	50,4	0,3	31,9
mai_P45	0,3	38,5	0,3	38,3	0,3	42,8	1,0	100,0	0,4	43,7	0,3	38,5	0,1	25,5	0,3	34,5	0,3	32,6	0,3	37,4	0,4	42,4	0,2	26,9
juin_P45	0,4	45,9	0,4	45,8	0,4	43,0	0,4	43,7	1,0	100,0	0,5	51,7	0,1	28,5	0,3	39,5	0,3	38,0	0,4	44,2	0,5	52,7	0,3	32,2
juillet_P45	0,4	45,1	0,4	44,3	0,4	42,8	0,3	38,6	0,5	51,7	1,0	100,0	0,2	30,6	0,3	39,5	0,3	37,7	0,4	44,4	0,5	52,1	0,3	32,1
août_P45	0,1	28,1	0,1	28,2	0,1	27,3	0,1	25,5	0,1	28,5	0,2	30,6	1,0	100,0	0,2	31,1	0,1	24,3	0,1	28,4	0,2	30,3	0,1	18,8
septembre_P45	0,4	41,7	0,3	39,8	0,3	38,2	0,3	34,5	0,3	39,5	0,3	39,5	0,2	31,1	1,0	100,0	0,3	37,4	0,4	42,1	0,4	45,9	0,3	30,9
octobre_P45	0,4	41,3	0,3	38,2	0,3	36,0	0,2	32,6	0,3	38,0	0,3	37,7	1,1	24,3	0,3	37,4	1,0	100,0	0,4	47,3	0,4	45,6	0,2	29,6
novembre_P45	0,5	53,1	0,4	47,2	0,4	43,4	0,3	37,4	0,4	44,2	0,4	44,4	0,1	28,4	0,4	42,0	0,4	47,3	1,0	100,0	0,6	57,2	0,3	35,4
2018_P45	0,6	59,8	0,5	56,7	0,4	50,4	0,4	42,4	0,5	52,7	0,5	52,1	0,2	30,3	0,4	45,9	0,4	45,6	0,6	57,2	1,0	100,0	0,4	45,0
VT	0,4	37,1	0,3	33,9	0,3	31,9	0,2	26,9	0,3	32,2	0,3	32,1	0,1	18,8	0,3	30,9	0,2	29,6	0,3	35,4	0,4	45,0	1,0	100,0

k : nombre de classes. VT : vérité terrain.

TAB. D.16 – Coefficients Kappa (K) et F-Scores moyens (FS) après comparaison pixel à pixel des classifications des synthèses de période 105 jours et de la VT avec 5 classes.

	mar._P105		mai_P105		juil._P105		sep._P105		nov._P105		2018_P105		VT	
<i>k</i> = 5														
L3A_P105	K	FS	K	FS	K	FS	K	FS	K	FS	K	FS	K	FS
mars_P105	1,0	100,0	0,5	52,9	0,5	49,6	0,4	46,0	0,6	57,2	0,6	64,0	0,4	37,8
mai_P105	0,5	52,9	1,0	100,0	0,6	63,1	0,4	43,8	0,5	48,6	0,6	58,3	0,3	33,9
juillet_P105	0,5	49,6	0,6	63,1	1,0	100,0	0,4	44,3	0,4	47,6	0,6	57,7	0,3	34,0
septembre_P105	0,4	46,0	0,4	43,8	0,4	44,3	1,0	100,0	0,5	49,5	0,5	50,9	0,3	32,3
novembre_P105	0,6	57,2	0,5	48,6	0,4	47,6	0,5	49,5	1,0	100,0	0,6	61,0	0,3	36,5
2018_P105	0,6	64,0	0,6	58,4	0,6	57,7	0,5	50,9	0,6	61,0	1,0	100,0	0,4	42,8
VT	0,4	37,8	0,3	33,9	0,3	34,0	0,3	32,3	0,3	36,5	0,4	42,8	1,0	100,0

TAB. D.17 – Coefficients Kappa (K) et F-Scores moyens (FS) après comparaison pixel à pixel des classifications des synthèses de période 165 jours et de la VT avec 5 classes.

	avr._P165		juil._P165		oct._P165		2018_P165		VT	
<i>k</i> = 5										
L3A_P165	K	FS	K	FS	K	FS	K	FS	K	FS
avril_P165	1,0	100,0	0,5	54,2	0,6	57,1	0,6	66,1	0,4	39,5
juillet_P165	0,5	54,2	1,0	100,0	0,5	53,7	0,6	61,0	0,3	34,5
octobre_P165	0,6	57,1	0,5	53,7	1,0	100,0	0,7	65,5	0,4	37,8
2018_P165	0,6	66,1	0,6	61,0	0,7	65,5	1,0	100,0	0,4	42,3
VT	0,4	39,5	0,3	34,5	0,4	37,8	0,4	42,3	1,0	100,0

k : nombre de classes. VT : vérité terrain.

D.1.3 Zone d'étude ZONE1

D.1.3.1 Stabilité du *Random Forest* par entraînement sur l'étendue d'un bloc de tuiles Sentinel-2

D.1.3.1.1 En absence d'images Sentinel-1

Classifications

Modèle1 Le Tableau D.23 présente les différentes valeurs du coefficient Kappa (K) et du F-Score moyen (FS) obtenues au terme de la comparaison pixel à pixel des classifications de séries temporelles d'images optiques Sentinel-2_L2A des douze mois et de l'année complète 2018 et de la VT en utilisant la légende à 12 classes, de la zone d'étude ZONE1 avec le Modèle1 (T33PTM-T33PUM-T33PUL_T33PTL-T33PTK-T33PUK).

Modèle2 Le Tableau D.24 présente les différentes valeurs du coefficient Kappa (K) et du F-Score moyen (FS) obtenues au terme de la comparaison pixel à pixel des classifications de séries temporelles d'images optiques Sentinel-2_L2A des douze mois et de l'année complète 2018 et de la VT en utilisant la légende à 12 classes, de la zone d'étude ZONE1 avec le Modèle2 (T33PTM-T33PUM-T33PUL-T33PTL_T33PTK-T33PUK).

Modèle3 Le Tableau D.25 présente les différentes valeurs du coefficient Kappa (K) et du F-Score moyen (FS) obtenues au terme de la comparaison pixel à pixel des classifications de séries temporelles d'images optiques Sentinel-2_L2A des douze mois et de l'année complète 2018 et de la VT en utilisant

TAB. D.18 – Coefficients Kappa (K) et F-Scores moyens (FS) obtenus par comparaison pixel à pixel des classifications des synthèses mensuelles de périodes 45 et de leur synthèse fusion 2018_P45 de séries temporelles d'images optiques et radar Sentinel-1_L1/-2_L3A et de la vérité terrain (VT) avec la légende à 5 classes, de la zone d'intérêt T32NPL.

	fév._P45		mar._P45		avr._P45		mai_P45		juin_P45		juil._P45		aoû._P45		sep._P45		oct._P45		nov._P45		2018_P45		VT		
<i>k</i> = 5	K	FS	K	FS	K	FS	K	FS	K	FS	K	FS	K	FS	K	FS	K	FS	K	FS	K	FS	K	FS	
L1-L3A_P45																									
février_P45	1,0	100,0	0,5	53,8	0,4	47,0	0,3	37,5	0,5	46,9	0,4	45,5	0,2	29,3	0,4	40,8	0,3	40,4	0,5	53,0	0,7	62,6	0,4	37,4	
mars_P45	0,5	53,8	1,0	100,0	0,4	47,6	0,3	36,5	0,4	46,9	0,4	44,5	0,2	29,6	0,3	38,5	0,3	37,6	0,4	46,7	0,6	58,2	0,3	34,3	
avril_P45	0,4	47,0	0,4	47,6	1,0	100,0	0,3	42,2	0,4	44,4	0,4	43,0	0,1	27,9	0,3	37,3	0,3	36,4	0,4	42,9	0,5	51,5	0,3	32,2	
mai_P45	0,3	37,5	0,3	36,5	0,3	42,2	1,0	100,0	0,3	42,3	0,3	37,4	0,1	25,1	0,2	33,2	0,2	31,9	0,3	36,2	0,4	42,3	0,2	27,2	
juin_P45	0,5	46,9	0,4	46,9	0,4	44,4	0,3	42,3	1,0	100,0	0,5	52,9	0,2	30,1	0,3	38,6	0,3	37,3	0,4	44,5	0,5	54,9	0,3	31,9	
juillet_P45	0,4	45,5	0,4	44,5	0,4	43,0	0,3	37,4	0,5	52,9	1,0	100,0	0,2	31,5	0,3	38,7	0,3	37,0	0,4	43,9	0,5	52,7	0,3	32,3	
août_P45	0,2	29,3	0,2	29,6	0,1	27,9	0,1	25,1	0,2	30,1	0,2	31,5	1,0	100,0	0,2	30,6	0,1	24,5	0,2	28,7	0,2	32,2	0,1	19,2	
septembre_P45	0,4	40,8	0,3	38,5	0,3	37,3	0,2	33,2	0,3	38,6	0,3	38,7	0,2	30,6	1,0	100,0	0,3	36,7	0,3	40,6	0,4	44,9	0,3	30,3	
octobre_P45	0,3	40,4	0,3	37,6	0,3	36,4	0,2	31,9	0,3	37,3	0,3	37,0	0,1	24,5	0,3	36,7	1,0	100,0	0,4	47,6	0,4	46,3	0,3	31,2	
novembre_P45	0,5	53,0	0,4	46,7	0,4	42,9	0,3	36,2	0,4	44,5	0,4	43,9	0,2	28,7	0,3	40,6	0,4	47,6	1,0	100,0	0,6	57,4	0,4	36,0	
2018_P45	0,7	62,6	0,6	58,2	0,5	51,5	0,4	42,3	0,5	54,9	0,5	52,7	0,2	32,2	0,4	44,9	0,4	46,3	0,6	57,4	1,0	100,0	0,4	44,4	
VT	0,4	37,4	0,3	34,3	0,3	32,2	0,2	27,2	0,3	31,9	0,3	32,2	0,1	19,2	0,3	30,3	0,3	31,2	0,4	36,0	0,4	44,4	1,0	100,0	

k : nombre de classes. VT : vérité terrain.

TAB. D.19 – Coefficients Kappa (K) et F-Scores moyens (FS) après comparaison pixel à pixel des classifications des synthèses de période 105 jours et de la VT avec 5 classes.

	mar._P105		mai_P105		juil._P105		sep._P105		nov._P105		2018_P105		VT	
<i>k</i> = 5														
L1-L3A_P105	K	FS	K	FS	K	FS	K	FS	K	FS	K	FS	K	FS
mars_P105	1,0	100,0	0,5	53,0	0,5	49,8	0,5	46,2	0,5	56,3	0,6	63,4	0,4	36,9
mai_P105	0,5	53,0	1,0	100,0	0,6	62,0	0,4	43,7	0,4	47,8	0,5	58,1	0,3	33,4
juillet_P105	0,5	49,8	0,6	62,0	1,0	100,0	0,4	44,5	0,5	47,6	0,6	56,8	0,3	34,2
septembre_P105	0,5	46,2	0,4	43,7	0,4	44,5	1,0	100,0	0,5	49,1	0,5	50,8	0,3	32,0
novembre_P105	0,6	56,3	0,4	47,8	0,5	47,6	0,5	49,1	1,0	100,0	0,6	60,3	0,4	38,0
2018_P105	0,6	63,4	0,5	58,1	0,6	56,8	0,5	50,8	0,6	60,3	1,0	100,0	0,4	42,9
VT	0,4	36,9	0,3	33,4	0,3	34,2	0,3	32,0	0,4	38,0	0,4	42,9	1,0	100,0

TAB. D.20 – Coefficients Kappa (K) et F-Scores moyens (FS) après comparaison pixel à pixel des classifications des synthèses de période 165 jours et de la VT avec 5 classes.

	avr._P165		juil._P165		oct._P165		2018_P165		VT	
<i>k</i> = 5										
L1-L3A_P165	K	FS	K	FS	K	FS	K	FS	K	FS
avril_P165	1,0	100,0	0,5	56,7	0,5	56,6	0,7	68,7	0,4	38,9
juillet_P165	0,5	56,7	1,0	100,0	0,5	52,3	0,6	61,5	0,3	35,0
octobre_P165	0,6	56,5	0,5	52,3	1,0	100,0	0,6	63,5	0,7	68,7
2018_P165	0,7	68,7	0,6	61,5	0,6	63,5	1,0	100,0	0,4	42,7
VT	0,4	38,8	0,3	35,0	0,4	37,9	0,4	42,7	1,0	100,0

k : nombre de classes. VT : vérité terrain.

la légende à 12 classes, de la zone d'étude ZONE1 avec le Modèle3 (T33PTM-T33PUM-T33PUL-T33PTL-T33PTK_T33PUK).

Modèle4 Le Tableau D.26 présente les différentes valeurs du coefficient Kappa (K) et du F-Score moyen (FS) obtenues au terme de la comparaison pixel à pixel des classifications de séries temporelles d'images optiques Sentinel-2_L2A des douze mois et de l'année complète 2018 et de la VT en utilisant la légende à 12 classes, de la zone d'étude ZONE1 avec le Modèle4 (T33PTM-T33PUM-T33PUL-T33PTL-T33PTK-T33PUK).

D.2 Comparaison par régions des distributions de classes

D.2.1 Zone d'intérêt T33PUL

D.2.1.1 Auto-entraînement sur l'étendue d'une tuile Sentinel-2

D.2.1.1.1 En absence d'images Sentinel-1

Classifications

Le Tableau D.27 présente les moyennes des distances entre les distributions de classes calculées au sein de cellules de taille 200 pixels extraites des classifications de séries temporelles d'images optiques Sentinel-2_L2A des douze mois et de l'année complète 2018 et de la VT en utilisant la légende à 12 classes, de la zone d'intérêt T33PUL.

TAB. D.21 – Coefficients Kappa (K) et F-Scores moyens (FS) obtenus par comparaison pixel à pixel de la classification de la synthèse 2018_P45 ainsi que des onze fusions de classifications des synthèses mensuelles de période 45 jours de séries temporelles d'images optiques et radar Sentinel-1_L1/-2_L3A et de la vérité terrain (VT) avec la légende à 5 classes, de la zone d'intérêt T32NPL.

	bayer		bayermarge		DSV2		HanV2		min		moy		moymarge		PCRV2		RF		SVM-lin_t0		SVM-rbf_t2		2018_P45		VT			
	K	FS																										
<i>L1-L3A_P45</i>																												
bayer	1,0	100,0	0,9	95,0	0,9	96,0	0,9	96,7	0,9	92,0	0,9	98,0	0,9	94,0	0,9	91,0	0,9	97,0	0,9	96,6	0,9	97,5	0,9	94,0	0,7	66,9		
bayermarge	0,9	97,0	1,0	100,0	0,9	92,1	0,8	72,8	0,8	79,9	0,9	92,0	0,9	94,6	0,9	90,2	0,8	79,5	0,8	77,4	0,8	78,2	0,8	74,5	0,4	46,9		
DSV2	0,9	99,0	0,9	92,1	1,0	100,0	0,8	70,2	0,8	80,8	0,9	89,1	0,9	85,5	0,9	88,1	0,8	75,2	0,8	72,5	0,8	73,6	0,8	70,7	0,4	41,3		
HanV2	0,9	96,7	0,8	72,8	0,8	70,2	1,0	100,0	0,7	66,5	0,8	74,5	0,8	72,4	0,8	77,8	0,72	71,3	0,7	69,6	0,7	70,5	0,7	65,5	0,4	41,9		
min	0,9	99,1	0,8	79,9	0,8	80,8	0,7	66,5	1,0	100,0	0,8	77,1	0,8	75,6	0,8	77,7	0,7	69,5	0,7	68,8	0,7	68,7	0,7	67,8	0,4	45,6		
moy	0,9	93,0	0,9	92,0	0,9	89,1	0,8	74,5	0,8	77,1	1,0	100,0	0,9	91,4	0,9	91,6	0,8	80,9	0,8	78,3	0,8	79,2	0,8	75,7	0,4	47,4		
moymarge	0,9	92,0	0,9	94,6	0,9	85,5	0,8	72,4	0,8	75,6	0,9	91,4	1,0	100,0	0,9	88,9	0,8	80,0	0,8	77,7	0,8	78,8	0,8	73,8	0,4	44,9		
PCRV2	0,9	95,0	0,9	90,2	0,9	88,1	0,8	77,8	0,8	77,7	0,9	91,6	0,9	88,9	1,0	100,0	0,8	79,4	0,8	77,1	0,8	78,1	0,8	73,6	0,4	44,2		
RF	1,0	97,0	0,8	79,5	0,8	75,2	0,7	71,3	0,7	69,5	0,8	80,9	0,8	80,0	0,8	79,4	1,0	100,0	0,8	85,9	0,9	87,2	0,8	74,3	0,4	44,7		
SVM-lin_t0	0,9	96,6	0,8	77,4	0,8	72,5	0,7	69,6	0,7	68,8	0,8	78,3	0,8	77,7	0,8	77,1	0,8	85,9	1,0	100,0	0,9	93,9	0,7	73,1	0,4	44,2		
SVM-rbf_t2	0,9	97,5	0,8	78,2	0,8	73,6	0,7	70,5	0,7	68,7	0,8	79,2	0,8	78,8	0,8	78,1	0,9	87,2	0,9	93,9	1,0	100,0	0,7	73,3	0,4	44,0		
2018_P45	0,9	94,0	0,8	74,5	0,8	70,7	0,7	65,5	0,7	67,8	0,8	75,7	0,8	73,8	0,8	73,6	0,8	74,3	0,7	73,1	0,7	73,3	1,0	100,0	0,4	44,4		
VT	0,7	66,9	0,4	46,9	0,4	41,0	0,4	41,9	0,4	45,6	0,4	47,4	0,4	44,9	0,4	44,2	0,4	44,7	0,4	44,2	0,4	44,0	0,4	44,4	1,0	100,0		

k : nombre de classes. VT : vérité terrain.

TAB. D.22 – Coefficients Kappa (K) et F-Scores moyens (FS) obtenus par comparaison pixel à pixel de la classification de la synthèse mensuelle juin_P315 ainsi que des onze fusions de classifications des synthèses mensuelles de période 45 jours de séries temporelles d'images optiques et radar Sentinel-1_L1/-2_L3A et de la vérité terrain (VT) avec la légende à 5 classes, de la zone d'intérêt T32NPL.

	bayer		bayermarge		DSV2		HanV2		min		moy		moymarge		PCRv2		RF		SVM-lin_t0		SVM-rbf_t2		2018_P315		VT			
	K	FS	K	FS	K	FS	K	FS	K	FS	K	FS	K	FS	K	FS	K	FS	K	FS	K	FS	K	FS	K	FS		
<i>L1-L3A_P315</i>																												
bayer	1,0	100,0	0,9	99,1	0,9	99,8	0,9	99,7	0,9	97,3	0,9	99,4	0,9	98,8	0,9	99,3	0,8	78,2	0,9	91,2	0,9	90,6	0,9	90,0	0,4	39,2		
bayermarge	0,9	99,2	1,0	100,0	0,9	99,0	0,9	96,6	0,9	99,3	0,9	99,6	0,9	98,7	0,8	78,3	0,9	91,1	0,9	90,5	0,9	90,3	0,4	39,3	0,9	99,8		
DSV2	0,9	99,0	0,9	92,0	1,0	100,0	0,9	97,5	0,9	99,2	0,9	98,6	0,9	99,2	0,8	78,2	0,9	91,1	0,9	90,6	0,9	90,0	0,4	39,2	0,9	99,7		
HanV2	0,9	99,0	0,9	99,7	0,9	99,0	1,0	100,0	0,9	97,3	0,9	98,7	0,9	99,3	0,8	78,2	0,9	91,2	0,9	90,6	0,9	90,0	0,4	39,2	0,9	97,3		
min	0,9	96,6	0,9	97,5	0,9	97,4	0,9	97,0	1,0	100,0	0,9	96,2	0,9	96,9	0,8	77,7	0,9	90,5	0,9	90,0	0,9	89,4	0,4	39,1	0,9	99,4		
moy	0,9	99,3	0,9	99,2	0,9	99,3	0,9	96,7	0,9	90,0	1,0	100,0	0,9	99,0	0,8	78,2	0,9	91,1	0,9	90,5	0,9	90,1	0,4	39,4	0,9	98,8		
moymarge	0,1	99,6	0,9	98,6	0,9	98,7	0,9	96,2	0,9	99,3	0,9	99,0	1,0	100,0	0,8	78,2	0,9	91,0	0,9	90,5	0,9	90,5	0,4	39,4	0,9	99,3		
PCRv2	0,9	98,7	0,9	99,2	0,9	99,3	0,9	96,9	0,9	99,0	0,9	98,4	0,9	98,0	1,0	100,0	0,9	91,4	0,9	90,9	0,9	89,9	0,4	39,1	0,8	78,2		
RF	0,8	78,3	0,8	78,2	0,8	78,2	0,8	77,7	0,8	78,2	0,8	78,2	0,8	78,3	0,9	98,0	1,0	100,0	0,8	80,5	0,8	77,8	0,3	35,3	0,9	91,2		
SVM-lin_t0	0,9	91,1	0,9	91,1	0,9	91,2	0,9	90,5	0,9	91,1	0,9	91,0	0,9	91,4	0,8	80,0	0,9	99,0	1,0	100,0	0,9	89,3	0,4	37,8	0,9	90,6		
SVM-rbf_t2	0,9	90,5	0,9	90,6	0,9	90,6	0,9	90,0	0,9	90,5	0,9	90,5	0,9	90,9	0,8	80,5	1,0	98,3	0,9	88,9	1,0	100,0	0,9	90,0	0,9	90,3		
2018_P315	0,9	89,9	0,9	90,0	0,9	89,4	0,9	90,1	0,9	90,4	0,9	89,9	0,8	77,8	0,9	89,3	0,9	88,9	0,9	97,0	0,4	39,7	1,0	100,0	0,4	39,3		
VT	0,4	39,2	0,4	39,2	0,4	39,1	0,4	39,4	0,4	39,4	0,4	39,1	0,3	35,3	0,4	37,8	0,4	37,5	0,4	39,7	0,9	96,0	0,9	99,0	1,0	100,0		

k : nombre de classes. VT : vérité terrain.

TAB. D.23 – Coefficients Kappa (K) et F-Scores moyens (FS) après comparaison pixel à pixel des classifications de séries d’images Sentinel-2_L2A et de la VT avec 12 classes.

	jan.		mar.		mai		juil.		sep.		nov.		2018		VT	
<i>k = 12</i>																
L2A	K	FS	K	FS	K	FS	K	FS	K	FS	K	FS	K	FS	K	FS
janvier	1,0	100,0	0,4	45,2	0,3	35,9	0,2	28,8	0,2	30,0	0,3	39,6	0,4	47,1	0,1	6,0
mars	0,4	46,2	1,0	100,0	0,3	35,6	0,3	28,2	0,2	28,0	0,3	37,2	0,4	44,1	0,1	6,0
mai	0,3	35,9	0,3	35,6	1,0	100,0	0,3	28,6	0,2	27,1	0,3	34,9	0,3	38,5	0,1	6,0
juillet	0,2	28,8	0,3	28,2	0,3	28,6	1,0	100,0	0,2	24,3	0,2	29,7	0,3	32,5	0,1	5,8
septembre	0,2	30,0	0,2	28,4	0,2	27,1	0,2	24,3	1,0	100,0	0,3	34,4	0,3	38,8	0,1	5,5
novembre	0,3	39,6	0,3	37,2	0,3	34,9	0,2	29,7	0,3	34,4	1,0	100,0	0,4	48,0	0,1	4,8
2018	0,4	47,1	0,4	44,1	0,3	38,5	0,3	32,5	0,3	38,8	0,4	48,0	1,0	100,0	0,1	5,7
VT	0,1	6,0	0,1	6,0	0,1	6,0	0,1	5,8	0,1	5,5	0,1	4,8	0,1	5,7	1,0	100,0

TAB. D.24 – Coefficients Kappa (K) et F-Scores moyens (FS) après comparaison pixel à pixel des classifications de séries d’images Sentinel-2_L2A et de la VT avec 12 classes.

	jan.		mar.		mai		juil.		sep.		nov.		2018		VT	
<i>k = 12</i>																
L2A	K	FS	K	FS	K	FS	K	FS	K	FS	K	FS	K	FS	K	FS
janvier	1,0	100,0	0,3	35,0	0,3	35,0	0,2	28,6	0,2	33,6	0,4	42,7	0,4	46,2	0,1	5,7
mars	0,3	35,0	1,0	100,0	0,3	35,0	0,3	35,0	0,3	35,0	0,3	35,0	0,3	35,0	0,3	35,0
mai	0,3	35,0	0,3	35,0	1,0	100,0	0,3	29,9	0,2	29,9	0,3	35,4	0,4	44,3	0,1	5,8
juillet	0,2	28,6	0,3	29,9	0,3	29,9	1,0	100,0	0,2	26,0	0,3	30,9	0,3	33,9	0,1	5,7
septembre	0,2	33,6	0,2	29,1	0,2	29,1	0,3	28,9	1,0	100,0	0,2	36,4	0,3	40,0	0,1	6,0
novembre	0,4	42,7	0,3	35,4	0,3	35,4	0,3	30,9	0,2	36,4	1,0	100,0	0,4	48,4	0,1	5,2
2018	0,4	46,2	0,4	43,3	0,4	43,3	0,3	33,9	0,3	40,0	0,4	48,4	1,0	100,0	0,1	6,2
VT	0,1	5,7	0,3	35,0	0,1	5,8	0,1	5,7	0,1	6,0	0,1	5,2	0,1	6,2	1,0	100,0

k : nombre de classes. VT : vérité terrain.

D.2.1.1.2 En présence d’images Sentinel-1

Classifications

Le Tableau D.28 présente les moyennes des distances entre les distributions de classes calculées au sein de cellules de taille 200 pixels extraites des classifications de séries temporelles d’images optiques et radar Sentinel-1_L1/-2_L2A des douze mois et de l’année complète 2018 et de la VT en utilisant la légende à 12 classes, de la zone d’intérêt T33PUL.

Fusions de classifications

Le Tableau D.29 présente les moyennes des distances entre les distributions de classes calculées au sein de cellules de taille 200 pixels extraites de la classification de l’année complète 2018 et des onze fusions de classifications mensuelles, de séries temporelles d’images optiques et radar Sentinel-1_L1/-2_L2A et de la VT en utilisant la légende à 12 classes, de la zone d’intérêt T33PUL.

D.2.1.2 Sensibilité aux périodes de synthèse mensuelle de séries temporelles d’images Sentinel-2

D.2.1.2.1 En absence d’images Sentinel-1

TAB. D.25 – Coefficients Kappa (K) et F-Scores moyens (FS) après comparaison pixel à pixel des classifications de séries d’images Sentinel-2_L2A et de la VT avec 12 classes.

	jan.		mar.		mai		juil.		sep.		nov.		2018		VT	
<i>k = 12</i>																
L2A	K	FS	K	FS	K	FS	K	FS	K	FS	K	FS	K	FS	K	FS
janvier	1,0	100,0	0,4	46,8	0,3	34,0	0,2	28,6	0,2	33,3	0,3	37,7	0,5	48,7	0,1	6,1
mars	0,4	46,8	1,0	100,0	0,3	34,6	0,2	28,4	0,2	30,3	0,3	34,9	0,4	45,6	0,1	5,5
mai	0,3	34,0	0,3	34,6	1,0	100,0	0,2	28,4	0,2	27,9	0,3	31,1	0,3	37,5	0,1	5,7
juillet	0,2	28,6	0,2	28,4	0,2	28,4	1,0	100,0	0,2	25,3	0,2	27,6	0,3	32,1	0,1	5,9
septembre	0,2	33,3	0,2	30,3	0,2	27,9	0,2	25,3	1,0	100,0	0,3	32,8	0,3	40,7	0,1	5,4
novembre	0,3	37,7	0,3	34,9	0,3	31,1	0,2	27,6	0,3	32,8	1,0	100,0	0,4	42,7	0,1	5,0
2018	0,5	48,7	0,4	45,6	0,3	37,5	0,3	32,1	0,3	40,7	0,4	42,7	1,0	100,0	0,1	6,6
VT	0,1	6,1	0,1	5,5	0,1	5,7	0,1	5,9	0,1	5,4	0,1	5,0	0,1	6,6	1,0	100,0

TAB. D.26 – Coefficients Kappa (K) et F-Scores moyens (FS) après comparaison pixel à pixel des classifications de séries d’images Sentinel-2_L2A et de la VT avec 12 classes.

	jan.		mar.		mai		juil.		sep.		nov.		2018		VT	
<i>k = 12</i>																
L2A	K	FS	K	FS	K	FS	K	FS	K	FS	K	FS	K	FS	K	FS
janvier	1,0	100,0	0,4	46,7	0,3	36,9	0,2	27,2	0,2	33,2	0,3	35,7	0,4	47,4	0,1	5,9
mars	0,4	46,7	1,0	100,0	0,3	36,5	0,2	27,1	0,2	32,9	0,3	34,0	0,4	47,7	0,1	6,3
mai	0,3	36,9	0,3	36,5	1,0	100,0	0,3	28,5	0,2	30,1	0,3	31,0	0,4	41,2	0,1	5,9
juillet	0,2	27,8	0,2	27,1	0,3	28,5	1,0	100,0	0,2	25,8	0,2	26,2	0,3	32,5	0,1	5,3
septembre	0,2	33,2	0,2	32,9	0,2	30,1	0,2	25,8	1,0	100,0	0,2	32,5	0,3	40,9	0,1	5,9
novembre	0,3	35,7	0,3	34,0	0,3	31,0	0,2	26,0	0,2	32,5	1,0	100,0	0,4	42,4	0,1	6,3
2018	0,4	47,4	0,4	47,7	0,4	41,2	0,3	32,5	0,3	40,9	0,4	42,4	1,0	100,0	0,1	6,3
VT	0,1	5,9	0,1	6,3	0,1	5,9	0,1	5,3	0,1	5,9	0,1	6,3	0,1	6,3	1,0	100,0

k : nombre de classes. VT : vérité terrain.

Classifications

5 classes Les Tableaux D.30, D.31 et D.32 présentent les moyennes des distances entre les distributions de classes calculées au sein de cellules de taille *200 pixels* extraites des classifications des synthèses respectives de périodes *45, 105* et *165* jours de séries temporelles d’images optiques Sentinel-2_L3A et de la vérité terrain (VT) avec la légende à 5 classes, de la zone d’intérêt T33PUL.

D.2.1.2.2 En présence d’images Sentinel-1

Classifications

5 classes Les Tableaux D.33, D.34 et D.35 présentent les moyennes des distances entre les distributions de classes calculées au sein de cellules de taille *200 pixels* extraites des classifications des synthèses respectives de périodes *45, 105* et *165* jours de séries temporelles d’images optiques et radar Sentinel-1_L1/-2_L3A et de la vérité terrain (VT) avec la légende à 5 classes, de la zone d’intérêt T33PUL.

Fusions de classifications

5 classes Les Tableaux D.36 et D.37 présentent les moyennes des distances entre les distributions de classes calculées au sein de cellules de taille *200 pixels* extraites respectivement des classifications

<i>L2A</i>	jan.	fév.	mar.	avr.	mai	juin	juil.	août.	sep.	oct.	nov.	déc.	2018	<i>VT</i>
janvier	0.00	0.21	0.76	0.27	0.79	0.31	0.39	0.72	0.64	0.18	0.18	0.15	0.65	1.07
février	0.21	0.00	0.72	0.30	0.75	0.28	0.37	0.71	0.60	0.23	0.24	0.21	0.63	1.03
mars	0.76	0.72	0.00	0.77	0.41	0.75	0.75	0.90	0.41	0.75	0.75	0.75	0.35	0.46
avril	0.27	0.30	0.77	0.00	0.79	0.36	0.40	0.67	0.65	0.30	0.28	0.27	0.67	1.07
mai	0.79	0.75	0.41	0.79	0.00	0.76	0.75	0.90	0.45	0.78	0.78	0.78	0.51	0.57
juin	0.31	0.28	0.75	0.36	0.76	0.00	0.35	0.70	0.62	0.26	0.29	0.31	0.65	1.05
juillet	0.39	0.37	0.75	0.40	0.75	0.35	0.00	0.59	0.62	0.35	0.35	0.37	0.68	1.03
août	0.76	0.71	0.90	0.67	0.90	0.70	0.59	0.00	0.79	0.70	0.70	0.71	0.87	1.11
septembre	0.64	0.60	0.41	0.65	0.45	0.62	0.62	0.79	0.00	0.62	0.63	0.63	0.38	0.65
octobre	0.18	0.75	0.30	0.78	0.26	0.35	0.70	0.62	0.67	0.00	0.16	0.17	0.64	1.07
novembre	0.18	0.24	0.75	0.28	0.78	0.29	0.35	0.70	0.63	0.15	0.00	0.14	0.64	1.06
décembre	0.15	0.21	0.75	0.27	0.78	0.31	0.37	0.71	0.63	0.17	0.14	0.00	0.64	1.06
2018	0.65	0.63	0.35	0.67	0.51	0.65	0.68	0.87	0.38	0.64	0.64	0.64	0.00	0.65
<i>VT</i>	1.07	1.03	0.46	1.07	0.57	1.05	1.03	1.11	0.65	1.07	1.06	1.06	0.65	0.00

TAB. D.27 – Moyennes des distances entre les histogrammes calculées au sein de cellules de taille 200 pixels extraites des classifications de séries temporelles d'images optiques Sentinel-2_L2A et de la vérité terrain (*VT*) avec la légende à 12 classes, de la zone d'intérêt T33PUL.

<i>L1-L2A</i>	jan.	fév.	mar.	avr.	mai	juil.	août.	sept.	oct.	nov.	déc.	2018	VT
janvier	0.00	0.12	0.16	0.27	0.29	0.26	0.39	0.38	0.19	0.18	0.17	0.17	0.23
février	0.12	0.00	0.18	0.26	0.30	0.26	0.37	0.35	0.21	0.19	0.16	0.20	0.29
mars	0.16	0.18	0.00	0.27	0.32	0.28	0.41	0.39	0.23	0.21	0.22	0.16	0.28
avril	0.27	0.26	0.27	0.00	0.35	0.32	0.40	0.41	0.31	0.29	0.28	0.28	0.23
mai	0.29	0.30	0.32	0.35	0.00	0.23	0.38	0.40	0.30	0.31	0.31	0.27	0.35
juin	0.26	0.26	0.28	0.32	0.23	0.00	0.34	0.34	0.23	0.24	0.26	0.22	0.29
juillet	0.39	0.37	0.41	0.40	0.38	0.34	0.00	0.38	0.34	0.35	0.37	0.40	0.39
août	0.73	0.71	0.74	0.69	0.73	0.70	0.59	0.69	0.71	0.71	0.71	0.74	0.75
septembre	0.38	0.35	0.39	0.41	0.40	0.34	0.38	0.00	0.31	0.34	0.33	0.36	0.38
octobre	0.19	0.21	0.23	0.31	0.30	0.23	0.34	0.31	0.00	0.17	0.19	0.18	0.25
novembre	0.18	0.19	0.21	0.29	0.31	0.24	0.35	0.34	0.17	0.00	0.16	0.21	0.25
décembre	0.17	0.16	0.22	0.28	0.31	0.26	0.37	0.33	0.19	0.16	0.00	0.21	0.31
2018	0.17	0.20	0.16	0.28	0.27	0.22	0.40	0.36	0.18	0.21	0.21	0.00	0.26
VT	0.23	0.29	0.28	0.23	0.35	0.29	0.39	0.38	0.25	0.25	0.31	0.26	0.00

TAB. D.28 – Moyennes des distances entre les histogrammes calculées au sein de cellules de taille 200 pixels extraites des classifications de séries temporelles d'images optiques et radar Sentinel-1_L1/-2_L2A et de la vérité terrain (VT) avec la légende à 12 classes, de la zone d'intérêt T33PUL.

<i>L1-L2A</i>	<i>bayes</i>	<i>bmge</i>	<i>DSV2</i>	<i>HanV2</i>	<i>min</i>	<i>moy</i>	<i>mmge</i>	<i>PCRV2</i>	<i>RF</i>	<i>t0</i>	<i>t2</i>	<i>2018</i>	<i>VT</i>
<i>bayes</i>	0.00	0.22	0.22	0.28	0.24	0.22	0.22	0.23	0.87	0.83	0.88	0.26	1.17
<i>bayesmarge</i>	0.22	0.00	0.02	0.11	0.05	0.02	0.01	0.04	0.79	0.75	0.80	0.12	1.10
<i>DSV2</i>	0.22	0.02	0.00	0.11	0.05	0.01	0.03	0.05	0.79	0.75	0.80	0.12	1.10
<i>HanV2</i>	0.28	0.11	0.11	0.00	0.11	0.11	0.11	0.10	0.77	0.73	0.78	0.16	1.08
<i>min</i>	0.24	0.05	0.05	0.11	0.00	0.05	0.06	0.07	0.78	0.74	0.79	0.12	1.08
<i>moy</i>	0.22	0.02	0.01	0.11	0.05	0.00	0.02	0.05	0.79	0.75	0.80	0.12	1.10
<i>moymarge</i>	0.22	0.01	0.03	0.11	0.06	0.02	0.00	0.04	0.79	0.75	0.80	0.12	1.10
<i>PCRV2</i>	0.23	0.04	0.05	0.10	0.07	0.05	0.04	0.00	0.79	0.75	0.80	0.14	1.10
<i>RF</i>	0.87	0.79	0.79	0.77	0.78	0.79	0.79	0.79	0.00	0.12	0.10	0.78	0.45
<i>SVM-lin_t0</i>	0.83	0.75	0.75	0.73	0.74	0.75	0.75	0.75	0.12	0.00	0.09	0.74	0.49
<i>SVM-rbf_t2</i>	0.88	0.80	0.80	0.78	0.79	0.80	0.80	0.80	0.10	0.10	0.00	0.79	0.44
<i>2018</i>	0.26	0.12	0.12	0.16	0.12	0.12	0.12	0.14	0.78	0.74	0.79	0.00	1.09
<i>VT</i>	1.17	1.10	1.10	1.10	1.09	1.10	1.10	1.10	0.45	0.49	0.44	1.09	0.00

TAB. D.29 – Moyennes des distances entre les histogrammes calculées au sein de cellules de taille 200 pixels extraites de la classification de l'année complète 2018 et des onze fusions de classifications mensuelles, de séries temporelles d'images optiques et radar Sentinel-1_L1/-2_L2A et de la VT avec la légende à 12 classes, de la zone d'intérêt T33PULL.

<i>L3A_P45</i>	fév.	mar.	avr.	mai	juil.	août.	sept.	oct.	nov.	2018	VT
février	0.00	0.23	0.25	0.27	0.24	0.27	0.28	0.22	0.18	0.26	0.49
mars	0.23	0.00	0.25	0.34	0.33	0.29	0.32	0.26	0.25	0.26	0.47
avril	0.25	0.25	0.00	0.35	0.32	0.31	0.33	0.29	0.25	0.26	0.47
mai	0.27	0.34	0.35	0.00	0.22	0.32	0.36	0.29	0.28	0.38	0.60
juin	0.24	0.33	0.32	0.22	0.00	0.28	0.34	0.28	0.25	0.31	0.44
juillet	0.27	0.29	0.31	0.32	0.28	0.00	0.31	0.25	0.25	0.30	0.58
août	0.55	0.56	0.57	0.61	0.57	0.52	0.56	0.57	0.56	0.58	0.88
septembre	0.28	0.32	0.33	0.36	0.34	0.31	0.00	0.27	0.25	0.30	0.52
octobre	0.22	0.26	0.29	0.29	0.28	0.25	0.27	0.00	0.13	0.27	0.55
novembre	0.18	0.25	0.25	0.28	0.25	0.25	0.25	0.13	0.00	0.24	0.51
2018	0.26	0.26	0.26	0.38	0.31	0.30	0.30	0.27	0.24	0.00	0.32
VT	0.49	0.47	0.47	0.60	0.44	0.58	0.52	0.55	0.51	0.32	0.00

TAB. D.30 – Moyennes des distances entre les histogrammes calculées au sein de cellules de taille 200 pixels extraites des classifications des synthèses de période 45 jours de séries temporelles d'images optiques Sentinel-2_L3A et de la VT avec la légende à 5 classes, de la zone d'intérêt T33PUL.

<i>L3A_P105</i>	mar.	mai	juil.	sept.	nov.	2018	VT
mars	0.00	0.20	0.38	0.25	0.20	0.22	0.48
mai	0.20	0.00	0.36	0.28	0.24	0.24	0.47
juillet	0.38	0.36	0.00	0.31	0.33	0.35	0.62
septembre	0.25	0.28	0.31	0.00	0.16	0.22	0.50
novembre	0.20	0.24	0.33	0.16	0.00	0.20	0.46
2018	0.22	0.24	0.35	0.22	0.20	0.00	0.41
VT	0.48	0.47	0.62	0.50	0.46	0.41	0.00

TAB. D.31 – Moyennes des distances entre les histogrammes issues des classifications des synthèses de période 105 jours et de la VT avec 5 classes.

<i>L3A_P165</i>	avr.	juil.	oct.	2018	VT
avril	0.00	0.28	0.25	0.27	0.54
juillet	0.28	0.00	0.23	0.22	0.48
octobre	0.25	0.23	0.00	0.23	0.52
2018	0.27	0.22	0.23	0.00	0.43
VT	0.54	0.48	0.52	0.43	0.00

TAB. D.32 – Moyennes des distances entre les histogrammes issues des classifications des synthèses de période 165 jours et de la VT avec 5 classes.

des synthèses *2018_P45* et *2018_P315* ainsi que des onze fusions de classifications des synthèses mensuelles de période 45 jours de séries temporelles d'images optiques et radar Sentinel-1_L1/-2_L3A et de la vérité terrain (VT) avec la légende à 5 classes, de la zone d'intérêt *T33PUL*.

D.2.2 Zone d'intérêt *T32NPL*

D.2.2.1 Auto-entraînement sur l'étendue d'une tuile Sentinel-2

D.2.2.1.1 En absence d'images Sentinel-1

Classifications

Le Tableau D.38 présente les moyennes des distances entre les distributions de classes calculées au sein de cellules de taille *200 pixels* extraites des classifications de séries temporelles d'images optiques Sentinel-2_L2A des douze mois et de l'année complète *2018* et de la VT en utilisant la légende à 12 classes, de la zone d'intérêt *T32NPL*.

D.2.2.1.2 En présence d'images Sentinel-1

<i>L1-L3A_P45</i>	fév.	mar.	avr.	mai	juil.	juil.	août.	sept.	oct.	nov.	2018	VT
février	0.00	0.23	0.25	0.27	0.24	0.27	0.55	0.28	0.22	0.18	0.26	0.49
mars	0.23	0.00	0.25	0.34	0.33	0.29	0.56	0.32	0.26	0.25	0.26	0.47
avril	0.25	0.25	0.00	0.35	0.32	0.31	0.57	0.33	0.29	0.25	0.26	0.47
mai	0.27	0.34	0.35	0.00	0.22	0.32	0.61	0.36	0.29	0.28	0.38	0.60
juin	0.24	0.33	0.32	0.22	0.00	0.28	0.57	0.34	0.28	0.25	0.31	0.44
juillet	0.27	0.29	0.31	0.32	0.28	0.00	0.52	0.31	0.25	0.25	0.30	0.58
août	0.55	0.56	0.57	0.61	0.57	0.52	0.00	0.56	0.57	0.56	0.58	0.88
septembre	0.28	0.32	0.33	0.36	0.34	0.31	0.56	0.00	0.27	0.25	0.30	0.52
octobre	0.22	0.26	0.29	0.29	0.28	0.25	0.57	0.27	0.00	0.13	0.27	0.55
novembre	0.18	0.25	0.25	0.28	0.25	0.25	0.56	0.25	0.13	0.00	0.24	0.51
2018	0.26	0.26	0.26	0.38	0.31	0.30	0.58	0.30	0.27	0.24	0.00	0.32
VT	0.49	0.47	0.47	0.60	0.44	0.58	0.88	0.52	0.55	0.51	0.32	0.00

TAB. D.33 – Moyennes des distances entre les histogrammes calculées au sein de cellules de taille 200 pixels extraites des classifications des synthèses de période 45 jours de séries temporelles d'images optiques et radar Sentinel-1_L1/-2_L3A et de la VT avec la légende à 5 classes, de la zone d'intérêt T33PUL.

<i>L1-L3A_P105</i>	mar.	mai	juil.	sept.	nov.	2018	VT
mars	0.00	0.20	0.38	0.25	0.20	0.22	0.48
mai	0.20	0.00	0.36	0.28	0.24	0.24	0.47
juillet	0.38	0.36	0.00	0.31	0.33	0.35	0.62
septembre	0.25	0.28	0.31	0.00	0.16	0.22	0.50
novembre	0.20	0.24	0.33	0.16	0.00	0.20	0.46
2018	0.22	0.24	0.35	0.22	0.20	0.00	0.41
VT	0.48	0.47	0.62	0.50	0.46	0.41	0.00

TAB. D.34 – Moyennes des distances entre les histogrammes issues des classifications des synthèses de période 105 jours et de la VT avec 5 classes.

<i>L1-L3A_P165</i>	avr.	juil.	oct.	2018	VT
avril	0.00	0.28	0.25	0.27	0.54
juillet	0.28	0.00	0.23	0.22	0.48
octobre	0.25	0.23	0.00	0.23	0.52
2018	0.27	0.22	0.23	0.00	0.43
VT	0.54	0.48	0.52	0.43	0.00

TAB. D.35 – Moyennes des distances entre les histogrammes issues des classifications des synthèses de période 165 jours et de la VT avec 5 classes.

Classifications

Le Tableau D.39 présente les moyennes des distances entre les distributions de classes calculées au sein de cellules de taille 200 pixels extraites des classifications de séries temporelles d'images optiques et radar Sentinel-1_L1/-2_L2A des douze mois et de l'année complète 2018 et de la VT en utilisant la légende à 12 classes, de la zone d'intérêt T32NPL.

Fusions de classifications

Le Tableau D.40 présente les moyennes des distances entre les distributions de classes calculées au sein de cellules de taille 200 pixels extraites de la classification de l'année complète 2018 et des onze fusions de classifications mensuelles, de séries temporelles d'images optiques et radar Sentinel-1_L1/-2_L2A et de la VT en utilisant la légende à 12 classes, de la zone d'intérêt T32NPL.

D.2.2.2 Sensibilité aux périodes de synthèse mensuelle de séries temporelles d'images Sentinel-2

D.2.2.2.1 En absence d'images Sentinel-1

<i>L1-L3A_P45</i>	bayes	bmge	DSV2	HanV2	min	moy	mmge	PCRV2	RF	t0	t2	2018	VT
bayes	0.00	0.20	0.20	0.25	0.24	0.19	0.19	0.20	0.21	0.22	0.20	0.29	0.29
bayesmarge	0.20	0.00	0.03	0.10	0.07	0.02	0.04	0.04	0.07	0.09	0.05	0.18	0.27
DSV2	0.20	0.03	0.00	0.10	0.06	0.03	0.06	0.05	0.07	0.09	0.05	0.19	0.27
HanV2	0.25	0.10	0.10	0.00	0.13	0.10	0.10	0.08	0.11	0.12	0.10	0.20	0.40
min	0.24	0.07	0.06	0.13	0.00	0.09	0.11	0.10	0.11	0.11	0.09	0.19	0.24
moy	0.19	0.02	0.03	0.10	0.09	0.00	0.03	0.03	0.07	0.09	0.05	0.19	0.38
moymarge	0.19	0.04	0.06	0.10	0.11	0.03	0.00	0.04	0.07	0.09	0.06	0.19	0.68
PCRV2	0.20	0.04	0.05	0.08	0.10	0.03	0.04	0.00	0.07	0.09	0.06	0.19	0.32
RF	0.21	0.07	0.07	0.11	0.11	0.07	0.07	0.07	0.00	0.06	0.04	0.19	0.35
SVM- <i>lin</i> _t0	0.22	0.09	0.09	0.12	0.11	0.09	0.09	0.09	0.06	0.00	0.06	0.18	0.31
SVM- <i>rbf</i> _t2	0.20	0.05	0.05	0.10	0.09	0.05	0.06	0.06	0.04	0.06	0.00	0.19	0.32
2018	0.29	0.18	0.19	0.20	0.19	0.19	0.19	0.19	0.19	0.18	0.19	0.00	0.22
VT	0.29	0.27	0.27	0.40	0.24	0.38	0.68	0.32	0.35	0.31	0.32	0.22	0.00

TAB. D.36 – Moyennes des distances entre les histogrammes calculées au sein de cellules de taille 200 pixels extraites de la classification de la synthèse 2018_P45 ainsi que des onze fusions de classifications des synthèses mensuelles de période 45 jours de séries temporelles d'images optiques et radar Sentinel-1_L1/-2_L3A et de la vérité terrain (VT) avec la légende à 5 classes, de la zone d'intérêt T33PUL.

<i>L1-L3A_P315</i>	<i>bayes</i>	<i>bmge</i>	<i>DSV2</i>	<i>HanV2</i>	<i>min</i>	<i>moy</i>	<i>mmge</i>	<i>PCRv2</i>	<i>RF</i>	<i>t0</i>	<i>t2</i>	<i>2018</i>	<i>VT</i>
<i>bayes</i>	0.00	0.00	0.00	0.00	0.01	0.00	0.01	0.00	0.09	0.04	0.21	0.04	0.29
<i>bayesmarge</i>	0.00	0.00	0.01	0.00	0.01	0.00	0.00	0.01	0.09	0.04	0.20	0.04	0.27
<i>DSV2</i>	0.00	0.01	0.00	0.00	0.01	0.00	0.01	0.00	0.09	0.04	0.21	0.04	0.27
<i>HanV2</i>	0.00	0.00	0.00	0.00	0.01	0.00	0.01	0.00	0.09	0.04	0.21	0.04	0.40
<i>min</i>	0.01	0.01	0.01	0.00	0.01	0.01	0.01	0.09	0.04	0.21	0.04	0.00	0.24
<i>moy</i>	0.00	0.00	0.00	0.00	0.01	0.00	0.00	0.00	0.09	0.04	0.21	0.04	0.38
<i>moymarge</i>	0.01	0.00	0.01	0.00	0.01	0.00	0.00	0.01	0.09	0.04	0.20	0.04	0.58
<i>PCRv2</i>	0.00	0.01	0.00	0.00	0.01	0.00	0.01	0.00	0.09	0.04	0.20	0.04	0.32
<i>RF</i>	0.09	0.09	0.09	0.09	0.09	0.09	0.09	0.09	0.00	0.09	0.16	0.11	0.35
<i>SVM-in_t0</i>	0.04	0.04	0.04	0.04	0.04	0.04	0.04	0.04	0.09	0.00	0.21	0.07	0.31
<i>SVM-rbf_t2</i>	0.21	0.20	0.21	0.21	0.21	0.21	0.20	0.20	0.16	0.21	0.00	0.20	0.32
<i>2018</i>	0.04	0.04	0.04	0.04	0.04	0.04	0.04	0.04	0.11	0.07	0.20	0.00	0.17
<i>VT</i>	0.29	0.27	0.27	0.40	0.24	0.38	0.58	0.32	0.35	0.31	0.32	0.17	0.00

TAB. D.37 – Moyennes des distances entre les histogrammes calculées au sein de cellules de taille 200 pixels extraites de la classification de la synthèse 2018_P315 ainsi que des onze fusions de classifications des synthèses mensuelles de période 45 jours de séries temporelles d'images optiques et radar Sentinel-1_L1/-2_L3A et de la vérité terrain (VT) avec la légende à 5 classes, de la zone d'intérêt T33PUL.

<i>L2A</i>	jan.	fév.	mar.	avr.	mai	juin	juil.	août.	sep.	oct.	nov.	déc.	2018	<i>VT</i>
janvier	0.00	0.22	0.41	0.66	0.31	0.37	0.50	0.78	0.31	0.67	0.23	0.25	0.19	0.50
février	0.22	0.00	0.42	0.68	0.34	0.41	0.52	0.82	0.35	0.70	0.25	0.25	0.23	0.50
mars	0.41	0.42	0.00	0.68	0.40	0.47	0.51	0.82	0.54	0.71	0.39	0.42	0.46	0.70
avril	0.66	0.68	0.68	0.00	0.61	0.61	0.47	0.48	0.64	0.79	0.63	0.64	0.68	0.82
mai	0.31	0.34	0.40	0.61	0.00	0.33	0.45	0.74	0.31	0.64	0.31	0.30	0.30	0.56
juin	0.37	0.41	0.47	0.61	0.33	0.00	0.48	0.74	0.39	0.64	0.37	0.34	0.37	0.60
juillet	0.50	0.52	0.51	0.47	0.45	0.48	0.00	0.57	0.52	0.70	0.48	0.49	0.52	0.71
août	0.78	0.82	0.82	0.48	0.74	0.74	0.57	0.00	0.75	0.86	0.77	0.78	0.81	0.90
septembre	0.31	0.35	0.54	0.64	0.31	0.39	0.52	0.75	0.00	0.67	0.32	0.32	0.29	0.53
octobre	0.67	0.70	0.71	0.79	0.64	0.64	0.70	0.86	0.67	0.00	0.66	0.67	0.70	0.85
novembre	0.23	0.25	0.38	0.63	0.31	0.37	0.48	0.77	0.32	0.66	0.00	0.24	0.23	0.52
décembre	0.25	0.25	0.42	0.64	0.30	0.34	0.49	0.78	0.32	0.67	0.24	0.00	0.25	0.55
2018	0.19	0.23	0.46	0.68	0.30	0.37	0.52	0.81	0.29	0.70	0.23	0.25	0.00	0.48
<i>VT</i>	0.50	0.50	0.70	0.82	0.56	0.60	0.71	0.90	0.53	0.85	0.52	0.55	0.48	0.00

TAB. D.38 – Moyennes des distances entre les histogrammes calculées au sein de cellules de taille 200 pixels extraites des classifications de séries temporelles d'images optiques Sentinel-2_L2A des mois et de l'année complète 2018 et de la vérité terrain (*VT*) avec la légende à 12 classes, de la zone d'intérêt T32NPL.

<i>L1-L2A</i>	jan.	fév.	mar.	avr.	mai	juil.	août.	sept.	oct.	nov.	déc.	2018	VT
janvier	0.00	0.23	0.31	0.66	0.31	0.37	0.49	0.32	0.68	0.23	0.28	0.19	0.50
février	0.23	0.00	0.35	0.68	0.35	0.42	0.52	0.39	0.72	0.25	0.34	0.23	0.53
mars	0.31	0.35	0.00	0.68	0.32	0.40	0.53	0.31	0.70	0.31	0.26	0.28	0.55
avril	0.66	0.68	0.68	0.00	0.60	0.61	0.48	0.64	0.79	0.63	0.68	0.68	0.82
mai	0.31	0.35	0.32	0.60	0.00	0.32	0.45	0.30	0.64	0.30	0.33	0.30	0.56
juin	0.37	0.42	0.40	0.61	0.32	0.00	0.48	0.39	0.64	0.36	0.41	0.38	0.60
juillet	0.49	0.52	0.53	0.48	0.45	0.48	0.00	0.51	0.71	0.48	0.55	0.51	0.69
août	0.79	0.83	0.80	0.49	0.74	0.73	0.57	0.75	0.86	0.78	0.80	0.82	0.90
septembre	0.32	0.39	0.31	0.64	0.30	0.39	0.51	0.00	0.67	0.32	0.27	0.31	0.53
octobre	0.68	0.72	0.70	0.79	0.64	0.64	0.71	0.67	0.00	0.66	0.71	0.70	0.85
novembre	0.23	0.25	0.31	0.63	0.30	0.36	0.48	0.32	0.66	0.00	0.27	0.20	0.52
décembre	0.28	0.34	0.26	0.68	0.33	0.41	0.55	0.27	0.71	0.27	0.00	0.25	0.52
2018	0.19	0.23	0.28	0.68	0.30	0.38	0.51	0.31	0.70	0.20	0.25	0.00	0.49
VT	0.50	0.53	0.55	0.82	0.56	0.60	0.69	0.53	0.85	0.52	0.52	0.49	0.00

TAB. D.39 – Moyennes des distances entre les histogrammes calculées au sein de cellules de taille 200 pixels extraites des classifications de séries temporelles d'images optiques et radar Sentinel-1_L1/-2_L2A des mois et de l'année complète 2018 et de la vérité terrain (VT) avec la légende à 12 classes, de la zone d'intérêt T32NPL.

<i>L1-L2A</i>	<i>bayes</i>	<i>bmge</i>	<i>DSV2</i>	<i>HanV2</i>	<i>min</i>	<i>moy</i>	<i>mmge</i>	<i>PCRV2</i>	<i>RF</i>	<i>t0</i>	<i>t2</i>	<i>2018</i>	<i>VT</i>
bayes	0.00	0.72	0.75	0.81	0.76	0.73	0.70	0.79	0.72	0.73	0.72	0.76	0.67
bayesmarge	0.72	0.00	0.08	0.18	0.29	0.04	0.06	0.15	0.11	0.18	0.13	0.13	0.50
DSV2	0.75	0.08	0.00	0.16	0.29	0.08	0.12	0.10	0.13	0.20	0.15	0.12	0.48
HanV2	0.81	0.18	0.16	0.00	0.28	0.19	0.22	0.16	0.22	0.23	0.23	0.16	0.48
min	0.76	0.29	0.29	0.28	0.00	0.32	0.32	0.36	0.35	0.31	0.34	0.32	0.50
moy	0.73	0.04	0.08	0.19	0.32	0.00	0.07	0.13	0.10	0.20	0.13	0.13	0.50
moymarge	0.70	0.06	0.12	0.22	0.32	0.07	0.00	0.19	0.11	0.18	0.13	0.15	0.53
PCRV2	0.79	0.15	0.10	0.16	0.36	0.13	0.19	0.00	0.17	0.24	0.18	0.13	0.47
RF	0.72	0.11	0.13	0.22	0.35	0.10	0.11	0.17	0.00	0.18	0.09	0.15	0.52
SVM-lin_t0	0.73	0.18	0.20	0.23	0.31	0.20	0.18	0.24	0.18	0.00	0.13	0.21	0.50
SVM-rbf_t2	0.72	0.13	0.15	0.23	0.34	0.13	0.13	0.18	0.09	0.13	0.00	0.16	0.50
2018	0.76	0.13	0.12	0.16	0.32	0.13	0.15	0.13	0.15	0.21	0.00	0.16	0.49
VT	0.67	0.50	0.48	0.48	0.50	0.50	0.53	0.47	0.52	0.50	0.50	0.49	0.00

TAB. D.40 – Moyennes des distances entre les histogrammes calculées au sein de cellules de taille 200 pixels extraites de la classification de l'année complète 2018 et des onze fusions de classifications mensuelles, de séries temporelles d'images optiques et radar Sentinel-1_L1/-2_L2A et de la VT avec la légende à 12 classes, de la zone d'intérêt T32NPL.

Classifications

5 classes Les Tableaux D.41, D.42 et D.43 présentent les moyennes des distances entre les distributions de classes calculées au sein de cellules de taille *200 pixels* extraites des classifications des synthèses respectives de périodes 45, 105 et 165 jours de séries temporelles d'images optiques Sentinel-2_L3A et de la vérité terrain (VT) avec la légende à 5 classes, de la zone d'intérêt T32NPL.

D.2.2.2.2 En présence d'images Sentinel-1

Classifications

5 classes Les Tableaux D.44, D.45 et D.46 présentent les moyennes des distances entre les distributions de classes calculées au sein de cellules de taille *200 pixels* extraites des classifications des synthèses respectives de périodes 45, 105 et 165 jours de séries temporelles d'images optiques et radar Sentinel-1_L1/-2_L3A et de la vérité terrain (VT) avec la légende à 5 classes, de la zone d'intérêt T32NPL.

Fusions de classifications

5 classes Les Tableaux D.47 et D.48 présentent les moyennes des distances entre les distributions de classes calculées au sein de cellules de taille *200 pixels* extraites respectivement des classifications des synthèses 2018_P45 et 2018_P315 ainsi que des onze fusions de classifications des synthèses mensuelles de période 45 jours de séries temporelles d'images optiques et radar Sentinel-1_L1/-2_L3A et de la vérité terrain (VT) avec la légende à 5 classes, de la zone d'intérêt T32NPL.

D.2.3 Zone d'étude ZONE1

D.2.3.1 Stabilité du *Random Forest* par entraînement sur l'étendue d'un bloc de tuiles Sentinel-2

D.2.3.1.1 En absence d'images Sentinel-1

Classifications

Modèle1 Le Tableau D.49 présente les moyennes des distances entre les distributions de classes calculées au sein de cellules de taille *200 pixels* extraites des classifications de séries temporelles d'images optiques Sentinel-2_L2A des douze mois et de l'année complète 2018 et de la VT en utilisant la légende à 12 classes, de la zone d'étude ZONE1 avec le Modèle1 (T33PTM-T33PUM-T33PUL_T33PTL-T33PTK-T33PUK).

Modèle2 Le Tableau D.50 présente les moyennes des distances entre les distributions de classes calculées au sein de cellules de taille *200 pixels* extraites des classifications de séries temporelles d'images optiques Sentinel-2_L2A des douze mois et de l'année complète 2018 et de la VT en utilisant la légende à 12 classes, de la zone d'étude ZONE1 avec le Modèle2 (T33PTM-T33PUM-T33PUL-T33PTL_T33PTK-T33PUK).

Modèle3 Le Tableau D.51 présente les moyennes des distances entre les distributions de classes calculées au sein de cellules de taille *200 pixels* extraites des classifications de séries temporelles d'images optiques Sentinel-2_L2A des douze mois et de l'année complète 2018 et de la VT en utilisant la légende à 12 classes, de la zone d'étude ZONE1 avec le Modèle3 (T33PTM-T33PUM-T33PUL-T33PTL-T33PTK_T33PUK).

<i>L3A_P45</i>	fév.	mar.	avr.	mai	juil.	août.	sep.	oct.	nov.	2018	VT
février	0.00	0.14	0.20	0.32	0.16	0.18	0.20	0.25	0.14	0.13	0.31
mars	0.14	0.00	0.18	0.31	0.16	0.18	0.20	0.27	0.17	0.16	0.33
avril	0.20	0.18	0.00	0.30	0.19	0.18	0.19	0.30	0.18	0.20	0.33
mai	0.32	0.31	0.30	0.00	0.27	0.28	0.29	0.35	0.30	0.34	0.51
juin	0.16	0.16	0.19	0.27	0.00	0.13	0.18	0.24	0.17	0.18	0.36
juillet	0.18	0.18	0.18	0.28	0.13	0.00	0.17	0.24	0.15	0.17	0.34
août	0.63	0.62	0.61	0.57	0.59	0.58	0.58	0.63	0.60	0.64	0.77
septembre	0.20	0.20	0.19	0.29	0.18	0.17	0.00	0.25	0.15	0.38	0.31
octobre	0.25	0.27	0.30	0.35	0.24	0.24	0.25	0.00	0.23	0.27	0.43
novembre	0.14	0.17	0.18	0.30	0.17	0.15	0.15	0.23	0.00	0.13	0.31
2018	0.13	0.16	0.20	0.34	0.18	0.17	0.18	0.27	0.13	0.00	0.25
VT	0.31	0.33	0.33	0.51	0.36	0.34	0.31	0.43	0.31	0.25	0.00

TAB. D.41 – Moyennes des distances entre les histogrammes calculées au sein de cellules de taille 200 pixels extraites des classifications des synthèses de période 45 jours de séries temporelles d'images optiques Sentinel-2_L3A et de la VT avec la légende à 5 classes, de la zone d'intérêt T32NPL.

<i>L3A_P105</i>	mar.	mai	juil.	sep.	nov.	2018	VT
mars	0.00	0.15	0.16	0.17	0.12	0.11	0.31
mai	0.15	0.00	0.08	0.19	0.16	0.15	0.36
juillet	0.16	0.08	0.00	0.16	0.15	0.14	0.34
septembre	0.17	0.19	0.16	0.00	0.14	0.18	0.34
novembre	0.12	0.16	0.15	0.14	0.00	0.12	0.33
2018	0.11	0.15	0.14	0.18	0.12	0.00	0.31
VT	0.31	0.36	0.34	0.34	0.33	0.31	0.00

TAB. D.42 – Moyennes des distances entre les histogrammes issues des classifications des synthèses de période 105 jours et de la VT avec 5 classes.

<i>L3A_P165</i>	avr.	juil.	oct.	2018	VT
avril	0.00	0.14	0.13	0.13	0.26
juillet	0.14	0.00	0.12	0.13	0.33
octobre	0.13	0.12	0.00	0.09	0.31
2018	0.13	0.13	0.09	0.00	0.31
VT	0.26	0.33	0.31	0.31	0.00

TAB. D.43 – Moyennes des distances entre les histogrammes issues des classifications des synthèses de période 165 jours et de la VT avec 5 classes.

Modèle4 Le Tableau D.52 présente les moyennes des distances entre les distributions de classes calculées au sein de cellules de taille 200 pixels extraites des classifications de séries temporelles d'images optiques Sentinel-2_L2A des douze mois et de l'année complète 2018 et de la VT en utilisant la légende à 12 classes, de la zone d'étude ZONE1 avec le Modèle4 (*T33PTM-T33PUM-T33PUL-T33PTL-T33PTK-T33PUK*).

<i>L1-L3A_P45</i>	fév.	mar.	avr.	mai	juin.	juil.	août.	sept.	oct.	nov.	2018	VT
février	0.00	0.17	0.19	0.34	0.18	0.19	0.62	0.23	0.26	0.14	0.11	0.32
mars	0.17	0.00	0.18	0.34	0.17	0.19	0.61	0.23	0.26	0.16	0.14	0.31
avril	0.19	0.18	0.00	0.30	0.18	0.19	0.60	0.21	0.23	0.18	0.19	0.33
mai	0.34	0.34	0.30	0.00	0.30	0.30	0.57	0.28	0.32	0.30	0.34	0.49
juin	0.18	0.17	0.18	0.30	0.00	0.14	0.58	0.22	0.25	0.17	0.17	0.38
juillet	0.19	0.19	0.19	0.30	0.14	0.00	0.57	0.20	0.23	0.17	0.19	0.35
août	0.62	0.61	0.60	0.57	0.58	0.57	0.00	0.56	0.61	0.59	0.63	0.77
septembre	0.23	0.23	0.21	0.28	0.22	0.20	0.56	0.00	0.19	0.17	0.23	0.32
octobre	0.26	0.26	0.23	0.32	0.25	0.23	0.61	0.19	0.00	0.18	0.25	0.31
novembre	0.14	0.16	0.18	0.30	0.17	0.17	0.59	0.17	0.18	0.00	0.14	0.30
2018	0.11	0.14	0.19	0.34	0.17	0.19	0.63	0.23	0.25	0.14	0.00	0.28
VT	0.32	0.31	0.33	0.49	0.38	0.35	0.77	0.32	0.31	0.30	0.28	0.00

TAB. D.44 – Moyennes des distances entre les histogrammes calculées au sein de cellules de taille 200 pixels extraites des classifications des synthèses de période 45 jours de séries temporelles d’images optiques et radar Sentinel-1_L1/-2_L3A et de la VT avec la légende à 5 classes, de la zone d’intérêt T32NPL.

<i>L1-L3A_P105</i>	mar.	mai	juil.	sept.	nov.	2018	VT
mars	0.00	0.16	0.15	0.17	0.14	0.12	0.34
mai	0.16	0.00	0.11	0.18	0.18	0.16	0.38
juillet	0.15	0.11	0.00	0.14	0.15	0.15	0.33
septembre	0.17	0.18	0.14	0.00	0.14	0.18	0.33
novembre	0.14	0.18	0.15	0.14	0.00	0.14	0.27
2018	0.12	0.16	0.15	0.18	0.14	0.00	0.32
VT	0.34	0.38	0.33	0.33	0.27	0.32	0.00

TAB. D.45 – Moyennes des distances entre les histogrammes issues des classifications des synthèses de période 105 jours et de la VT avec 5 classes.

<i>L1-L3A_P165</i>	avr.	juil.	oct.	2018	VT
avril	0.00	0.14	0.13	0.08	0.32
juillet	0.14	0.00	0.16	0.14	0.37
octobre	0.13	0.16	0.00	0.12	0.28
2018	0.08	0.14	0.12	0.00	0.29
VT	0.32	0.37	0.28	0.29	0.00

TAB. D.46 – Moyennes des distances entre les histogrammes issues des classifications des synthèses de période 165 jours et de la VT avec 5 classes.

<i>L1-L3A_P45</i>	<i>bayes</i>	<i>bmge</i>	<i>DSV2</i>	<i>HanV2</i>	<i>min</i>	<i>moy</i>	<i>mmge</i>	<i>PCRV2</i>	<i>RF</i>	<i>t0</i>	<i>t2</i>	<i>2018</i>	<i>VT</i>
<i>bayes</i>	0.00	0.14	0.15	0.19	0.16	0.14	0.14	0.15	0.17	0.19	0.18	0.18	0.29
<i>bayesmarge</i>	0.14	0.00	0.02	0.08	0.05	0.01	0.01	0.01	0.06	0.09	0.08	0.08	0.27
<i>DSV2</i>	0.15	0.02	0.00	0.08	0.05	0.02	0.02	0.02	0.07	0.10	0.09	0.08	0.28
<i>HanV2</i>	0.19	0.08	0.08	0.00	0.06	0.08	0.08	0.07	0.10	0.10	0.09	0.10	0.26
<i>min</i>	0.16	0.05	0.05	0.06	0.00	0.05	0.05	0.04	0.08	0.09	0.09	0.09	0.27
<i>moy</i>	0.14	0.01	0.02	0.08	0.05	0.00	0.01	0.02	0.07	0.10	0.08	0.08	0.27
<i>moymarge</i>	0.14	0.01	0.02	0.08	0.05	0.01	0.00	0.02	0.06	0.09	0.08	0.07	0.27
<i>PCRV2</i>	0.15	0.01	0.02	0.07	0.04	0.02	0.02	0.00	0.06	0.09	0.08	0.07	0.27
<i>RF</i>	0.17	0.06	0.07	0.10	0.08	0.07	0.06	0.06	0.00	0.04	0.03	0.07	0.29
<i>SVM-in_t0</i>	0.19	0.09	0.10	0.10	0.09	0.10	0.09	0.09	0.04	0.00	0.02	0.08	0.29
<i>SVM-rbf_t2</i>	0.18	0.08	0.09	0.09	0.09	0.08	0.08	0.08	0.03	0.02	0.00	0.07	0.28
<i>2018</i>	0.18	0.08	0.08	0.10	0.09	0.08	0.07	0.07	0.07	0.08	0.07	0.00	0.28
<i>VT</i>	0.29	0.27	0.28	0.26	0.27	0.27	0.27	0.27	0.29	0.29	0.28	0.28	0.00

TAB. D.47 – Moyennes des distances entre les histogrammes calculées au sein de cellules de taille 200 pixels extraites de la classification de la synthèse 2018_P45 ainsi que des onze fusions de classifications des synthèses mensuelles de période 45 jours de séries temporelles d'images optiques et radar Sentinel-1_L1/-2_L3A et de la vérité terrain (VT) avec la légende à 5 classes, de la zone d'intérêt T32NPL.

<i>L1-L3A_P315</i>	<i>bayes</i>	<i>bmge</i>	<i>DSV2</i>	<i>HanV2</i>	<i>min</i>	<i>moy</i>	<i>mmge</i>	<i>PCRv2</i>	<i>RF</i>	<i>t0</i>	<i>t2</i>	<i>2018</i>	<i>VT</i>
<i>bayes</i>	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.06	0.03	0.03	0.03	0.30
<i>bayesmarge</i>	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.06	0.03	0.03	0.03	0.30
<i>DSV2</i>	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.06	0.03	0.03	0.03	0.30
<i>HanV2</i>	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.06	0.03	0.03	0.03	0.30
<i>min</i>	0.00	0.00	0.00	0.00	0.00	0.00	0.01	0.06	0.03	0.03	0.03	0.03	0.30
<i>moy</i>	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.06	0.03	0.03	0.03	0.03	0.30
<i>moymarge</i>	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.06	0.03	0.03	0.03	0.03	0.30
<i>PCRv2</i>	0.00	0.00	0.00	0.01	0.00	0.00	0.00	0.06	0.03	0.03	0.03	0.03	0.32
<i>RF</i>	0.03	0.06	0.06	0.06	0.06	0.06	0.06	0.06	0.06	0.00	0.04	0.04	0.31
<i>SVM-lin_t0</i>	0.03	0.03	0.03	0.03	0.03	0.03	0.03	0.03	0.04	0.00	0.00	0.03	0.31
<i>SVM-rbf_t2</i>	0.03	0.03	0.03	0.03	0.03	0.03	0.03	0.03	0.04	0.00	0.00	0.02	0.31
<i>2018</i>	0.03	0.03	0.03	0.03	0.03	0.03	0.03	0.03	0.05	0.03	0.03	0.00	0.31
<i>VT</i>	0.30	0.30	0.30	0.30	0.30	0.30	0.30	0.30	0.32	0.31	0.31	0.31	0.00

TAB. D.48 – Moyennes des distances entre les histogrammes calculées au sein de cellules de taille 200 pixels extraites de la classification de la synthèse 2018_P315 ainsi que des onze fusions de classifications des synthèses mensuelles de période 45 jours de séries temporelles d'images optiques et radar Sentinel-1_L1/-2_L3A et de la vérité terrain (VT) avec la légende à 5 classes, de la zone d'intérêt T32NPL.

<i>L2A</i>	jan.	mar.	mai	juil.	sep.	nov.	2018	<i>VT</i>
janvier	0.00	0.32	0.36	0.37	0.39	0.36	0.32	0.57
mars	0.32	0.00	0.42	0.41	0.47	0.42	0.41	0.59
mai	0.36	0.42	0.00	0.42	0.44	0.41	0.43	0.56
juillet	0.37	0.41	0.42	0.00	0.40	0.38	0.43	0.59
septembre	0.39	0.47	0.44	0.40	0.00	0.33	0.38	0.69
novembre	0.36	0.42	0.41	0.38	0.33	0.00	0.33	0.68
2018	0.32	0.41	0.43	0.43	0.38	0.33	0.00	0.66
<i>VT</i>	0.57	0.59	0.56	0.59	0.69	0.68	0.66	0.00

TAB. D.49 – Moyennes des distances entre histogrammes des classifications du Modèle1 et de la *VT* avec 12 classes.

<i>L2A</i>	jan.	mar.	mai	juil.	sep.	nov.	2018	<i>VT</i>
janvier	0.00	0.42	0.39	0.36	0.29	0.40	0.42	0.74
mars	0.42	0.00	0.41	0.42	0.41	0.42	0.41	0.58
mai	0.42	0.42	0.00	0.40	0.44	0.41	0.36	0.58
juillet	0.39	0.40	0.40	0.00	0.38	0.37	0.44	0.63
septembre	0.36	0.44	0.44	0.38	0.00	0.34	0.45	0.69
novembre	0.29	0.41	0.41	0.37	0.34	0.00	0.37	0.69
2018	0.40	0.36	0.36	0.44	0.45	0.37	0.00	0.58
<i>VT</i>	0.74	0.58	0.58	0.63	0.69	0.69	0.58	0.00

TAB. D.50 – Moyennes des distances entre histogrammes des classifications du Modèle2 et de la *VT* avec 12 classes.

<i>L2A</i>	jan.	mar.	mai	juil.	sep.	nov.	2018	<i>VT</i>
janvier	0.00	0.32	0.41	0.38	0.37	0.32	0.29	0.58
mars	0.32	0.00	0.40	0.38	0.46	0.35	0.38	0.81
mai	0.41	0.40	0.00	0.40	0.46	0.41	0.48	0.72
juillet	0.38	0.38	0.40	0.00	0.42	0.38	0.45	0.67
septembre	0.37	0.46	0.46	0.42	0.00	0.36	0.42	0.62
novembre	0.32	0.35	0.41	0.38	0.36	0.00	0.38	0.66
2018	0.39	0.38	0.48	0.45	0.42	0.38	0.00	0.55
<i>VT</i>	0.58	0.81	0.72	0.67	0.62	0.66	0.55	0.00

TAB. D.51 – Moyennes des distances entre histogrammes des classifications du Modèle3 et de la *VT* avec 12 classes.

<i>L2A</i>	jan.	mar.	mai	juil.	sep.	nov.	2018	<i>VT</i>
janvier	0.00	0.27	0.36	0.40	0.38	0.38	0.32	0.57
mars	0.27	0.00	0.37	0.43	0.39	0.38	0.33	0.59
mai	0.36	0.37	0.00	0.42	0.41	0.43	0.37	0.57
juillet	0.40	0.43	0.42	0.00	0.38	0.38	0.42	0.66
septembre	0.38	0.39	0.41	0.38	0.00	0.35	0.42	0.60
novembre	0.38	0.38	0.43	0.38	0.35	0.00	0.38	0.64
2018	0.32	0.33	0.37	0.42	0.42	0.38	0.00	0.57
<i>VT</i>	0.57	0.59	0.57	0.66	0.60	0.64	0.57	0.00

TAB. D.52 – Moyennes des distances entre histogrammes des classifications du Modèle4 et de la *VT* avec 12 classes.

Liste des publications

① Journal international à comité de lecture :

- ➔ TAGNE, H., A. LE-BRIS, D. MONKAM et C. MALLET (2023). « Improved Random Forest accuracy by joint use of time series of Sentinel-1 and Sentinel-2 L3A monthly cloud free syntheses images ». En préparation pour être soumis à *Remote Sensing*.

② Conférence internationale à comité de lecture :

- ➔ TAGNE, H., A. LE-BRIS, D. MONKAM et C. MALLET (2020). « Classification of time series of Sentinel-2 images for large scale mapping in Cameroon ». In : *International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences (ISPRS Archives)*.
- ➔ TAGNE, H., A. LE-BRIS, D. MONKAM et C. MALLET (2022). « Classification of vegetation classes by using time series of Sentinel-2 images for large scale mapping in Cameroon ». In : *International Annals of the Photogrammetry, Remote Sensing and Spatial Information Sciences (ISPRS Annals)*.

