



HAL
open science

Méthodes de Machine Learning pour le suivi de l'occupation du sol des deltas du Viêt-Nam

Chi-Nguyen Lam

► **To cite this version:**

Chi-Nguyen Lam. Méthodes de Machine Learning pour le suivi de l'occupation du sol des deltas du Viêt-Nam. Autre. Université de Bretagne occidentale - Brest, 2021. Français. NNT : 2021BRES0074 . tel-03770198

HAL Id: tel-03770198

<https://theses.hal.science/tel-03770198>

Submitted on 6 Sep 2022

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.

THESE DE DOCTORAT DE

L'UNIVERSITE
DE BRETAGNE OCCIDENTALE

ECOLE DOCTORALE N° 598
Sciences de la Mer et du littoral
Spécialité : Géomatique

Par

Chi-Nguyen LAM

Méthodes de Machine Learning pour le suivi de l'occupation du sol des deltas du Viêt-Nam

Thèse présentée et soutenue à Brest, le 07 octobre 2021

Unité de recherche : LETG – UMR CNRS 6554

Rapporteurs avant soutenance :

Dr Thomas CORPETTI, CNRS, LETG-Rennes UMR 6554,
Université de Rennes 2

Prof. Sébastien GADAL, CNRS ESPACE UMR 7300, Aix-
Marseille Université

Composition du Jury :

Directrice de thèse
Dr. HDR Simona NICULESCU, LETG-Brest UMR 6554, UBO.

Co-directeur de thèse
Prof. Bernard POTTIER, Lab-STICC, Département
Informatique, UBO

Prof. Hiep Xuan HUYNH, Département d'informatique,
Université de Can Tho, Vietnam (examineur)

Dr Dominique LAVENIER, CNRS, INRIA/IRISA, Université de
Rennes 1 (examineur)

Prof. Vincent RODIN, Lab-STICC, Département Informatique,
UBO (Président du Jury)

Dr Thomas CORPETTI, CNRS, LETG-Rennes UMR 6554,
Université de Rennes 2 (examineur)

Prof. Sébastien GADAL, CNRS ESPACE UMR 7300,
Aix-Marseille Université (examineur)

Remerciements

J'ai le plaisir d'exprimer ma profonde gratitude à Mme Simona NICULESCU, ma directrice de thèse, qui m'a encadré et guidé pour réaliser ce projet de thèse. Elle m'a inspiré au cours de ces quatre dernières années pour mener à terme mes recherches dans le domaine de la télédétection, qui est complètement nouveau pour moi. Merci de m'avoir donné cette merveilleuse opportunité.

Je tiens également à exprimer mes sincères remerciements à M. Bernard POTTIER, mon co-directeur, qui m'a aidé pour aborder ce sujet de recherche. Il m'a beaucoup aidé dans la procédure d'admission à l'école doctorale et dans la demande de mon visa d'entrée en France.

Ma thèse est réalisée dans le cadre d'une bourse du ministère de l'Éducation et de la Formation du Vietnam. Je tiens à remercier le Département de la formation à l'étranger et le ministère de l'Éducation et de la Formation du Vietnam ainsi que l'agence qui a maintenu et réparti mes bourses en France pendant la durée de ma thèse.

Je souhaite remercier mes amis, mes collègues du laboratoire LETG-Brest. En particulier, je tiens à remercier Soumia BENGOUFA, une amie qui m'a tant soutenu et aidé. Sans elle, je pense que je ne pourrais pas finaliser ma thèse dans les temps. Je voudrais remercier Laurence DAVIS, Isabelle MESCOFF, les gentilles collègues qui m'ont aidé dans la relecture de mon manuscrit.

Enfin et surtout, je tiens à remercier tous les membres de ma famille, qui m'ont donné la motivation pour continuer sur la voie de la recherche scientifique. Merci à mon épouse qui s'est occupée de la famille en mon absence qui a sympathisé et m'a motivé à continuer ma passion scientifique. Je tiens à remercier tous Yao et mes amis qui m'ont soutenu pendant mon séjour en France.

À Brest, le 17 septembre 2021

Chi-Nguyen LAM

Table de matière

Introduction générale.....	9
Contexte général et Problématique.....	9
Objectifs	10
Structure de la thèse.....	11
Partie 1 : Le système deltaïque vietnamien	12
Chapitre 1. Le système du Delta du Mékong	14
1.1. Type d'occupation du sol du delta du Mékong	15
1.1.1. La guerre du Viêt-Nam	15
1.1.2. Les activités aquacoles et les mangroves dans le delta du Mékong	16
1.1.3. Activités agricoles dans le delta du Mékong	17
1.1.4. Impact des conditions climatiques sur le delta du Mékong	18
1.2. Risque d'inondation dans le delta du Mékong	18
1.2.1. La sécheresse.....	20
1.2.2. L'intrusion des eaux salines	21
Chapitre 2. Le système du fleuve Rouge	22
2.1. Type d'occupation du sol du delta du fleuve Rouge	23
2.1.1. Les activités aquacoles	23
2.1.2. Les activités agricoles	23
2.1.3. La législation et Gestion spatiale du delta du fleuve Rouge.....	24
2.2. Impact des conditions climatiques sur le delta du fleuve Rouge.....	25
2.2.1. Risque d'inondation dans le delta du fleuve rouge.....	25
2.2.2. Intrusion des eaux salines	25
Chapitre 3. L'occupation du sol dans les deltas du Viêt-Nam	27
3.1. L'étude de changement de l'occupation/couverture du sol	27
3.2. Les données satellitaires et la détection de l'occupation du sol.....	28
3.3. L'étude du risque d'inondation	28
3.3.1. Étude de l'occupation du sol pour l'évaluation du risque d'inondation.....	29
3.3.2. Les données satellitaires et l'évaluation du risque d'inondation	30
Chapitre 4. Satellites Landsat et Sentinel	35
4.1. Le satellite Landsat	35
4.2. La constellation Sentinel	36
Partie 2 : Démarches Méthodologiques.....	39
Chapitre 5. Structuration des données et Prétraitement.....	40
5.1. Les images SAR : Sentinel-1	40
5.1.1. Les équations de radar.....	40
5.1.2. Les images SAR.....	43
5.1.3. Les images Sentinel-1	43
5.2. Les images optiques : Sentinel-2	47

5.3. Les données de série temporelle	48
5.3.1. Les données optiques de série temporelle	48
5.3.2. Les données radars de série temporelle.....	48
5.3.3. Synergie des données Optiques et RADARS	49
Chapitre 6. <i>Machine Learning</i> (Apprentissage automatique)	51
6.1. Définition Apprentissage Automatique	52
6.2. Définition Apprentissage Profond.....	53
6.3. La segmentation des images satellites.....	54
6.3.1. L'algorithme K-means	54
6.3.2. Meanshift.....	57
6.3.3. Multi-résolution Segmentation (MRS)	60
6.3.4. Superpixel (SLIC)	62
6.4. Les méthodes de classification	64
6.4.1. <i>Support Vector Machine</i> : SVM	65
6.4.2. Random forest.....	68
6.5. Méthodes de Deep Learning.....	70
6.5.1. Multilayer Perceptron – MLP	70
6.5.2. <i>Convolutional neural network</i> : CNN.....	76
6.6. Evaluation de la précision des classifications.....	78
6.6.1. La matrice de confusion	79
6.6.2. L'estimation des précisions	81
6.6.3. L'estimation des superficies.	82
6.6.4. Les exemples	82
Chapitre 7. L'Analyse orientée objet d'images satellite	87
7.1. Émergence de l'approche « orientée objet »	87
7.2. Définition du concept de GEOBIA	87
7.3. Evaluation de GEOBIA.....	88
7.3.1. Avantages de GEOBIA.....	88
7.3.2. Inconvénient de GEOBIA	88
7.4. Paradigme de GEOBIA.....	88
7.4.1. Etape de travail dans le cadre de GEOBIA.....	89
7.4.2. Méthodes de machine learning.....	89
7.4.3. Méthodes de deep learning	90
Partie 3 : De l'acquisition des données aux Applications	91
Chapitre 8. Détection des changements de l'occupation du sol dans le delta du fleuve Rouge (Viêt-Nam)	92
8.1. Zone d'étude	92
8.2. Données mises en œuvre	94
8.3. Méthodologie	96
8.3.1. Calcul du NDVI.....	96

8.3.2. Segmentation des images	98
8.3.3. Classification des images	100
8.4. Résultats et discussion	102
8.4.1. Résultat des Random Forest	102
8.5. Conclusions	105
Chapitre 9. Étude et cartographie de l'inondation au niveau du delta du Mékong .	106
9.1. Méthodologie	106
9.2. Les données SAR et la détection de l'extension de l'inondation :	107
9.2.1. Le suivi des inondations des rizières :	108
9.3. Zone d'étude	109
9.3.1. La culture du Riz au delta du Mékong	110
9.3.2. Régime hydro-météorologique du Mékong	110
9.4. Données utilisées	111
9.4.1. Les données satellitaires	111
9.4.2. Données environnementales	112
9.5. Méthode d'apprentissage automatique et classification	113
9.5.1. Segmentation d'images et extraction de caractéristiques	113
9.5.2. Construction du modèle du CNN	114
9.5.3. <i>Random Forest</i> (RF)	115
9.5.4. Évaluation de la précision	115
9.6. Résultats	116
9.6.1. Profils de rétrodiffusion de rizières	116
9.7. Validation et comparaison des modèles	120
9.7.1. L'évaluation de la précision du modèle CNN	120
9.7.2. L'évaluation de la précision du classificateur RF	122
9.8. Résultats des modèles : cartographie inondée et inondable	125
9.8.1. Cartographie de l'étendue des inondations	125
9.8.2. Cartographie des zones inondables	128
9.8.3. Discussion	131
Conclusion générale	132
Bibliographie	135
ANNEXE	152

Liste des figures

Figure 1 : Système des deltas au Viêt-Nam.....	13
Figure 2 : Photo de trois sorties d'avions C-123	16
Figure 3 : Le delta du fleuve Rouge au Vietnam	22
Figure 4 : Polarisation horizontale (noire) et verticale (rouge)	41
Figure 5 : Les modes du système Sentinel 1	44
Figure 6 : Graphe de prétraitement des images Sentinel-1	45
Figure 7 : Illustration des relations entre apprentissage automatique	51
Figure 8 : Le processus général de l'algorithme d'apprentissage supervisé.....	53
Figure 9 : L'architecture globale du Convolutional neural network (CNN)	54
Figure 10 : Le courbe des clusters k de 1 à 9, le coude est trouvé par $K = 3$	56
Figure 11 : Image optique Sentinel-2 sur TranDe au 20 février 2020.....	58
Figure 12 : Kmeans (A) $K=5$, (B) $K=10$, (C) $K=15$	58
Figure 13 : La courbe des clusters k de 1 à 25	58
Figure 14 : Segmentation de MeanShift avec la bande passante	60
Figure 15 : Segmentation par multi résolution	62
Figure 16 : Segmentations par SLIC.....	64
Figure 17 : Hyperplan de SVM (a) données séparables, (b) données non-séparables	66
Figure 18 : Hyperplan de SVM (a) données non-linéaires, (b) données transformées	67
Figure 19 : Exemple de forêt d'arbres de décision.....	70
Figure 20 : Un neurone dans le cerveau humain	71
Figure 21 : Un neurone artificiel.....	72
Figure 22 : Graphiques des fonctions d'activation	72
Figure 23 : Modèle d'un réseau de neurones.....	73
Figure 24 : Illustration de l'étape Feedforward	74
Figure 25 : Illustration de l'étape backpropagation.....	75
Figure 26 : Modèle CNN avec 02 couches convolutives	77
Figure 27 : Exemple de l'opération convolutive.....	78
Figure 28 : Fonctions Max-Pool et Avg-Pool.....	78
Figure 29 : Carte de l'occupation du sol de province An Giang et province Dong Thap	83
Figure 30 : L'occupation du sol en 2019 à gauche et en 2020 à droite.	85
Figure 31 : Relation entre les objets et la résolution spatiale.	87
Figure 32 : Processus de GEOBIA	89
Figure 33 : Modèle Générale de CNN.	90
Figure 34 : Delta du fleuve Rouge au Viêt-Nam.....	93
Figure 35 : Chaîne de prétraitement et de traitement.	98
Figure 36 : Segmentation ESP2.	99
Figure 37 : Modèle MLP	101
Figure 38 : Occupation du sol en 2016, 2017, 2018 à TienHai, ThaiBinh au Viet-Nam.	104

Figure 39 : Prétraitement et traitement d'image SAR Sentinel-1.....	107
Figure 40 : Représentation schématique des mécanismes de rétrodiffusion	108
Figure 41 : Zone d'etudes - Province AnGiang et Province DongThap	110
Figure 42 : Classificateur CNN généralisé avec l'architecture 2D-CNN.	114
Figure 43 : Profil temporel VH et VV.....	118
Figure 44 : a) Pluies quotidiennes et niveaux d'eau quotidiens du Mékong	119
Figure 45 : Cartographie des inondations par classification CNN par mois.....	126
Figure 46 : schéma synthétique a) Précipitations mensuelles moyennes	127
Figure 47 : Cartographie des inondations.....	130
Figure 48 : Points d'observation et de validation dans le delta du Mékong.	152
Figure 49 : Profils VH temporel des classes de l'occupation du sol en 2019.....	153
Figure 50 : Profils VV temporel des classes de l'occupation du sol en 2019.....	153
Figure 51 : Profils VH temporel des classes de l'occupation du sol en 2020.....	154
Figure 52 : Profils VV temporel des classes de l'occupation du sol en 2020.....	154

Liste des tableaux

Tableau 1 : Polarisation utilisées	42
Tableau 2 : Modes de système Sentinel-1.....	44
Tableau 3 : Récapitulatif des résolutions spectrale, spatiale et temporelle de Sentinel 2.....	47
Tableau 4 : Séries temporelles 2016, 2017,2018 au delta du fleuve Rouge.	48
Tableau 5 : Organisation des jeux de données SAR	49
Tableau 6 : Noyaux de SVM non linéaire.....	67
Tableau 7 : Matrice de confusion de k classes.	80
Tableau 8 : Etendue de la matrice de confusion.....	80
Tableau 9 : Matrice de confusion estimée.	81
Tableau 10 : Matrice de confusion de la carte d'occupation du sol.	83
Tableau 11 : Précisions des classifications de l'occupation du sol.....	83
Tableau 12 : Matrice de confusion estimée	84
Tableau 13 : Estimations des précisions de la carte de l'occupation du sol.	84
Tableau 14 : Matrice de changements de l'occupation du sol de 2019 à 2020.	85
Tableau 15 : Précisions estimées de la classification par CNN.....	86
Tableau 16 : Ensemble de données satellitaires disponibles.....	95
Tableau 17 : Résolutions spatiales et spectrales du satellite Sentinel-2.	95
Tableau 18 : Résolutions spatiales et spectrales du satellite Landsat-8.	96
Tableau 19 : Calendrier du riz dans la zone de la côte du delta du fleuve Rouge.....	97
Tableau 20 : Calendrier des cultures de riz et passages des Satellites	98
Tableau 21 : Précision globale et indice de kappa par classe.....	103
Tableau 22 : Comparaison des précisions globales par le modèle CNN.....	120
Tableau 23 : Précisions de l'utilisateur par le modèle CNN	121
Tableau 24 : Précisions du producteur par le modèle CNN	121
Tableau 25 : Comparaison des précisions globales par le modèle RF.....	123
Tableau 26 : Précisions de l'utilisateur par le modèle RF.....	123
Tableau 27 : Précisions du producteur par le modèle RF	124
Tableau 28 : Analyse spatiales des zones impactées par les inondations.	127
Tableau 29 : Superficie de LULC avant la saison des pluies en 2019 et 2020.....	128
Tableau 30 : Superficie des LULC non inondés en 2019 et 2020	130
Tableau 31: Nombre de points d'observation.	152
Tableau 32 : Code Python du modèle Multilayer Perceptron	155
Tableau 33 : Code Python du modèle Convolutional Neural Network.....	155

Introduction générale

Contexte général et Problématique

Les deltas sont parmi les zones les plus importantes au monde, fournissant une gamme variée de services écosystémiques essentiels au bien-être socio-économique. Ces deltas sont, en effet, les plus propices à l'habitation et l'occupation humaine sur la Terre. Elles connaissent d'importants changements de l'occupation et de couverture du sol en raison de la concentration de la population et des activités humaines (Bianchi et Allison, 2009). Ces occupations peuvent aussi bien avoir un impact positif et bénéfique pour le bien-être social et économique, comme elles peuvent avoir un impact négatif sur l'écosystème naturel et les questions environnementales (Lambin et Geist, 2006). Par ailleurs ces zones, qui sont le reflet des besoins humains, sont sévèrement affectées par les changements environnementaux et les activités anthropiques (Tilman, 2001). En effet, dans ce contexte de changements environnementaux et socio-économiques, l'étude de l'occupation du sol au niveau des zones deltaïques a dûment attiré l'attention des scientifiques (Minderhoud *et al.*, 2018).

Le système deltaïque joue un rôle très important dans l'Histoire, l'économie, la culture et l'environnement du Viêt-Nam. L'économie et la vie dans ce pays sont associées à l'existence et au développement de grands deltas fluviaux, à savoir le delta du Mékong et le delta du fleuve Rouge (Pruszek *et al.* 2002). Le type d'occupation du sol au niveau de ces deltas est intrinsèquement lié à des tendances du développement socio-économique du Viêt-Nam (Smajgl *et al.*, 2015). Ceci dépend de l'expansion de l'agriculture, principalement la riziculture ainsi que les activités aquacoles. En outre, les facteurs environnementaux jouent un rôle important dans le changement de l'occupation du sol dans ces deltas. Les épisodes de sécheresse se produisent de plus en plus fréquemment, entraînant des intrusions salines dans les zones côtières. Les changements compliqués des saisons d'inondation dans les deltas modifient les activités agricoles, conduisant ainsi à un changement de l'utilisation du sol afin de s'adapter au changement climatique (Bé *et al.*, 2017; Đạt *et al.*, 2012; Phung *et al.*, 2021).

Comparées aux investigations directes (sur le terrain), les données de télédétection fournissent une couverture synoptique des zones côtières et sont utiles pour des applications de surveillance détaillée (Mujabar et Chandrasekar, 2011). Les propriétés spectrales des images pourraient être utilisées pour extraire plusieurs caractéristiques du relief côtier (Hannv *et al.*, 2013), permettant de ce fait de répondre

aux besoins des scientifiques en matière d'acquisition rapide des données. Par ailleurs, aujourd'hui et avec la contribution des centres de recherche spatiale à l'échelle mondiale (ESA, NASA), les données de télédétection sont largement accessibles avec une bonne résolution spatiale et temporelle (Sentinel-1,2, Landsat-8). Ainsi, le lancement de nouveaux capteurs spatiaux, le progrès des technologies de télédétection, ont conduit à la création d'une énorme source d'informations. Un tel ensemble global de données offre des opportunités entièrement nouvelles pour une variété d'applications (Vali *et al.*, 2020).

Bien que ces données présentent un grand potentiel pour la prise de décisions dans des domaines critiques tels que la gestion des risques (inondation, sécheresse, érosion, etc.), elles ne sont pas exploitées à leur plein potentiel en fonction des besoins spécifiques (Kansakar et Hossain, 2016). En effet, le développement des techniques de traitement automatique et reproductible des données de télédétection, est nécessaire pour rendre le suivi des changements au niveau des zones deltaïques plus pertinent.

Le développement technologique notamment dans l'intelligence artificielle, et les algorithmes d'apprentissage automatique (*Machine Learning* et *Deep Learning*), a apporté de nombreux bénéfices. Récemment, plusieurs algorithmes comme *Support Vector Machine*, les réseaux neuronaux et *Random Forest*, ont été adoptés avec succès pour les applications de télédétection (Niculescu *et al.*, 2019) Ce processus traduit la cognition humaine à l'intelligence de la machine d'une manière plus sophistiquée (A.Gibril *et al.*, 2017).

Le traitement des données de télédétection à l'aide de diverses méthodes d'intelligence artificielle ou d'apprentissage automatique ont donné de bon résultats, cependant la sélection et l'évaluation de l'efficacité de chaque méthode reste un travail exigeant pour lesquels des efforts doivent être fournis.

Objectifs

Dans ce contexte, les objectifs de ce travail sont de :

- Proposer des méthodologies de traitement des données satellites pour la détection et de cartographie de l'occupation du sol au niveau des deux principaux deltas du Viêt-Nam, fleuve rouge et Mékong.
- Vérifier, valider et évaluer les résultats de traitement d'images satellitaires multi capteurs par de nombreuses approches, notamment

celles de la segmentation d'image et de l'apprentissage automatique peu profond et profond.

- Évaluer l'apport des méthodes d'apprentissage automatique à la cartographie des zones deltaïques dans un contexte de caractérisation d'un aléa (l'inondation) et d'analyse des enjeux (culture du riz).

Structure de la thèse

Pour mener à terme notre travail et atteindre ces objectifs, cette thèse se présente en trois parties.

- La première s'articule autour du système deltaïque au Viêt-Nam : nous mettons en avant les caractéristiques de deux principaux deltas du Viêt-Nam et les problématiques socio-économiques et environnementales existantes avec un état de l'art sur les avancées et les progrès de la télédétection et les données satellites.
- La deuxième partie concerne les méthodologies et les approches de télédétection qui ont été utilisées dans nos applications. Nous proposons un modèle général de traitement des données satellites, les principaux développements des algorithmes et méthodes de traitements, de segmentations, de classifications ainsi que les méthodes d'évaluation de la pertinence de ces dernières.
- La dernière partie dresse en détail nos études de cas et applications sur les deux Deltas du Viêt-Nam. Nous y présentons ainsi les méthodes, les modèles et les algorithmes utilisés afin de détecter le type d'occupation du sol. Nous posons un diagnostic, selon les interprétations des résultats, sur le phénomène de l'inondation et la riziculture au Viêt-Nam.

Partie 1 : Le système deltaïque vietnamien

Les deltas et les fleuves sont parmi les zones les plus attractives pour l'occupation et la population humaine. Par conséquent, elles connaissent une forte concentration des activités socio-économiques à fort potentiel, qui se développent et évoluent en fonction des besoins humains et des changements environnementaux globaux (Tilman, 2001). Ces occupations peuvent aussi bien avoir un impact positif et bénéfique pour le bien-être social et économique comme elles peuvent avoir un impact négatif sur l'écosystème naturel et les questions environnementales (Lambin et Geist, 2006)

Dans ce contexte d'augmentation des besoins humains, il est nécessaire de suivre l'état de l'occupation et de l'utilisation du sol et d'étudier ses impacts de grande portée sur l'environnement deltaïque. En effet, ceci a dû attirer l'attention des scientifiques, en représentant un défi pour trouver un équilibre entre l'environnement et les besoins socio-économiques (Foley *et al.*, 2005). Dans un contexte de développement durable et de gestion intégrée des zones sensibles.

Le système hydrographique au Viêt-Nam est structuré par le Mékong au sud et le Fleuve Rouge au nord (*Figure 1*), en constituant un ensemble de 41 000 km d'alluvions auxquels s'ajoutent 3 100 km de canaux.

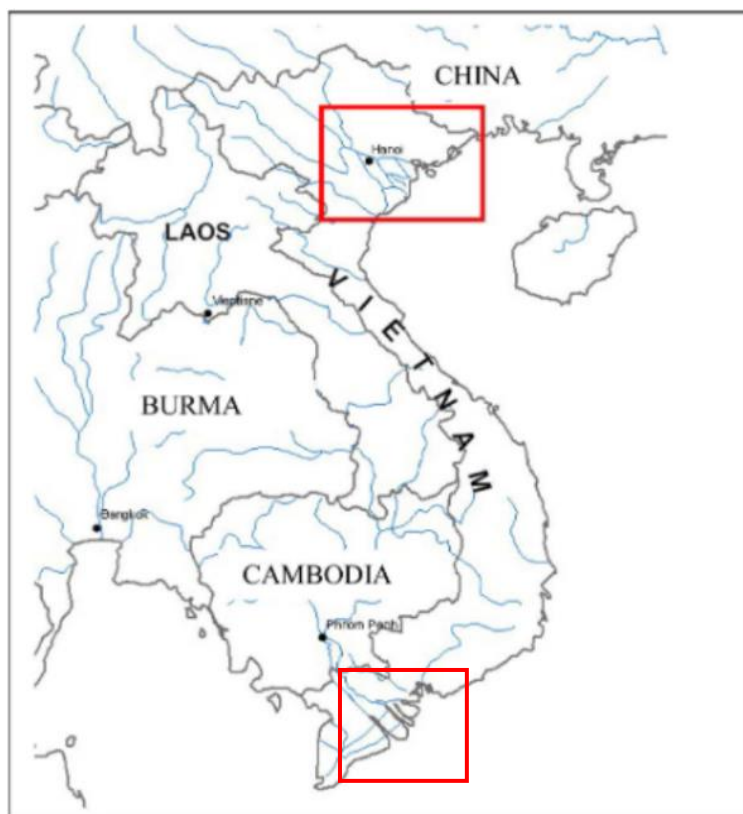


Figure 1 : Système des deltas au Viêt-Nam

Chapitre 1. Le système du Delta du Mékong

Le fleuve Mékong est parmi les plus grands à l'échelle mondiale, et le troisième fleuve le plus long d'Asie. Il prend sa source dans la chaîne de l'Himalaya et se jette dans la mer de Chine au Viêt-Nam, en parcourant plus de 4 000 km et en irriguant 6 pays. En Chine, où il est appelé Lancang Jiang, il traverse la région du Kham entre le Tibet et le Sichuan, puis il pénètre en Birmanie, et au Laos où il prend le nom de Mékong (le fleuve mère), pour tracer enfin vers la Thaïlande.

Le delta du Mékong commence à *Phnom Penh* au Cambodge, où le fleuve se divise en deux branches principales de cours d'eau, le *Tien Giang* (bras antérieur) et le *Hau Giang* (bras postérieur) ; arrivant en mer de Chine au Viêt-Nam, les deux branches se ramifient en neuf canaux principaux, d'où l'appellation *Cuu Long* « le fleuve de neufs dragons ». Le delta s'étend sur environ 270 km depuis son sommet jusqu'à la côte, formant une vaste plaine triangulaire d'environ 55 000 km², presque entièrement située à moins de cinq mètres au-dessus du niveau de la mer.

Le delta s'est formé grâce au processus de sédimentation et d'érosion, ainsi qu'aux énormes volumes d'alluvions que le fleuve de Mékong transporte. En effet, il gagne plusieurs mètres sur la mer de façon périodique avec un taux d'accrétion de 150 m par an à certains endroits (Hashimoto, 2001). Une ceinture côtière d'environ 600 km et d'une altitude légèrement supérieure est créée par l'action combinée des dépôts fluviaux et du forçage de la mer (vagues et courant côtier).

Avec son climat tropical humide, le delta du Mékong est caractérisé par des températures mensuelles moyennes constamment élevées (25-29°C) et de fortes précipitations saisonnières (1 200-2 300 mm) (Hung, 2017), par conséquent le débit du fleuve Mékong présente de fortes variations saisonnières.

En raison de ses caractéristiques climatiques favorables, le delta du Mékong connaît un régime de cultures tout au long de l'année. Actuellement il présente une grande plaine qui héberge plus de 18 millions d'habitants. Ses principales villes sont *My Tho*, *Vinh Long*, *Can Tho* et *Chau Doc*.

Par ailleurs, le Viêt-Nam est un pays agricole d'excellence, selon les données de l'Organisation des Nations Unies pour l'alimentation et l'agriculture (FAO) il est classé cinquième producteur de riz et troisième exportateur mondial de produits aquatiques (FAO, 2016). Le delta de Mékong est l'une des régions les plus fertiles, et l'une des zones agricoles les plus productives au Viêt-Nam (Wilder et Phuong, 2002)

et du monde. Ses terres fertiles ainsi que le climat chaud et humide du sud-est asiatique ont largement favorisé la riziculture, d'où le surnom de « Bol de riz du Viêt-Nam ». Par ailleurs, le delta du Mékong contient les plus grandes zones aquacoles, qui représentent 70 % de sa superficie, en fournissant plus de 52 % de la production totale du delta (Truong et Do, 2018). Elle contribue à environ 55 % de la production aquatique nationale et à environ 51 % des exportations vietnamiennes des produits aquatiques (Quang, 2002).

1.1. Type d'occupation du sol du delta du Mékong

Le type d'occupation du sol est le résultat de l'interaction entre les facteurs socio-économiques et les facteurs naturels. Ces facteurs déterminent les limites de l'occupation du sol et les conditions pour provoquer des changements. Les facteurs naturels comprennent principalement les facteurs biologiques et physiques, tels que le changement climatique, le type du sol, l'hydrologie, la topographie, et la géomorphologie (Dumanski et Pieri, 2000).

Le type d'occupation du sol dans le delta du Mékong dépend largement des tendances du développement socio-économique du Viêt-Nam (Smajgl *et al.*, 2015). Ceci est intrinsèquement lié à l'expansion de l'agriculture, principalement la riziculture ainsi qu'aux activités aquacoles.

En outre, au fil des années, d'importants changements ont eu comme forces motrices des événements nationaux tels que la guerre du Viêt-Nam ainsi que la politique de gestion spéciale des terres agricoles, aquacoles et des mangroves.

1.1.1 La guerre du Viêt-Nam

Dans les années 1954 à 1975, pendant que le Viêt-Nam était en guerre, l'armée américaine organisait des attaques chimiques et pulvérisait des défoliants sur de grandes surfaces terrestres (*Figure 2*) au sud du pays, y compris les forêts, les espaces boisés, les marécages et les mangroves (Dorian, 2015). Le but était d'éradiquer les abris militaires et les sites de stockage de nourriture vietnamiens mais ceci n'a pas été sans conséquence sur les écosystèmes et l'environnement. Le delta du Mékong n'a pas échappé à ces attaques chimiques, car il y abritait de nombreuses stations d'approvisionnement en nourriture ainsi que des bases militaires pour le déploiement stratégique.

En 1968, environ 600 000 ha de terres ont été pulvérisés avec des produits chimiques et plus de 20 % des zones forestières du sud du Viêt-Nam ont été défoliées, dont environ 104 939 ha (36 %) de mangroves (NAS, 1974).

Par conséquent, plus de 2 millions d'hectares de forêts et de mangroves côtières au Viêt-Nam ont été détruits. Dorian Brunet, (2015) indique, d'après les archives américaines, que près de 14 % de ces missions ont ciblé des rizières et d'autres cultures, ainsi, les surfaces agricoles détruites sont estimées à plus de 236 000 hectares et 300 000 tonnes de récoltes ont été perdues (Liu *et al.*, 2020).

1.1.2 Les activités aquacoles et les mangroves dans le delta du Mékong

L'industrie de l'aquaculture a joué un rôle important dans la dynamique de l'occupation du sol. Étant le troisième exportateur mondial de crevettes, les activités aquacoles occupent une place importante dans l'économie nationale du Viêt-Nam. En conséquence, grâce aux encouragements du gouvernement, les agriculteurs locaux ont investi dans l'aquaculture.



Figure 2 : Photo de trois sorties d'avions C-123 dispersant des herbicides lors d'une mission Ranch Hand au-dessus du Sud-Vietnam

Le delta du Mékong possède un littoral de plus de 600 km, avec des conditions naturelles favorables au développement de l'aquaculture. En effet, à partir de 1980 des bassins aquacoles sont apparus dans certaines zones côtières du delta du Mékong, et l'aquaculture a commencé à se développer à un rythme important, en dépit des mangroves.

Pour encadrer cette expansion et restaurer les systèmes de mangrove, une réglementation a été instaurée en 1991 (64/QD.UB (28/3/1991), autorisant les agriculteurs à consacrer 30 % des terres allouées à l'aquaculture ou à l'agriculture, et à préserver ou restaurer plus de 70 % des forêts de mangrove. Cela a conduit à l'émergence d'un nouveau type d'occupation du sol, qui est le système complexe mangrove-aquaculture (Ha *et al.*, 2014). Cependant, ce système de gestion n'a pas permis de réduire la surface d'aquaculture, où il a été constaté un coût écologique important dans le delta du Mékong. Le gouvernement vietnamien a augmenté les contrôles.

En effet, dans les années 2000 et 2001, les résolutions 09/NQ-CP et 1116, respectivement, ont encouragé les agriculteurs à convertir plutôt les terres salines côtières en fermes aquatiques en développant les activités de pisciculture et l'élevage de crevettes. Avec la demande croissante en produits aquacoles, les agriculteurs sont passés de l'agriculture à l'aquaculture (Trung *et al.*, 2007).

1.1.3 Activités agricoles dans le delta du Mékong

Les moyens de subsistance des populations dépendent du riz dès le début du peuplement du delta, en tirant d'abord profit des conditions naturelles, puis en modifiant le paysage au moyen d'infrastructures hydrauliques à grande échelle pour permettre la culture du riz dans des zones où elle n'était pas possible auparavant (Biggs, 2012; Taylor, 2014).

Dans la première moitié du XX^{ème} siècle, la politique de monoculture du riz, qui reposait sur un système instable de crédit et de dette, a provoqué le ressentiment des paysans et des troubles sociaux (Biggs, 2012). Ce qui a provoqué la forte ré-orientation vers l'activité aquacole. Cette expansion de l'aquaculture est la principale raison du déclin de la surface agricole. Cependant, jusqu'aux années 1998, malgré la croissance rapide de l'aquaculture dans les zones côtières, la superficie des terres agricoles était toujours supérieure à 3 millions d'hectares. Si 266 752 hectares de terres agricoles ont été convertis en activité d'aquaculture, cette superficie avait été rapidement compensée par la transformation des terres inutilisées et des forêts humides en terres agricoles.

Les bénéfices tirés de la crevette étaient supérieurs à la valeur économique issue de la culture du riz (Tran *et al.*, 2015). En effet, les revenus élevés obtenus par l'élevage de produits aquatiques ont encouragé les agriculteurs à étendre les zones d'aquaculture en dépit des terres agricoles.

Après 1998, une transformation massive des terres de culture dans le delta du Mékong en aquaculture a été remarquée. En conséquence, les superficies agricoles ont rapidement diminué.

Face à cette situation d'expansion de l'aquaculture, la tendance du développement de l'utilisation des terres dans le delta du Mékong à partir de la fin du XX^{ème} siècle a consisté principalement à développer un système intégré d'agriculture et d'aquaculture.

1.1.4 Impact des conditions climatiques sur le delta du Mékong

Considérant les changements environnementaux globaux, les problèmes écologiques dans le delta du Mékong ont été exacerbés. En effet, le delta du Mékong est menacé par différentes sources de problèmes environnementaux à savoir, le manque d'eau douce, l'intrusion d'eau salée, l'acidification des sols, et la pollution des masses d'eaux estuariennes (Hoanh *et al.*, 2002; Quang, 2002). En plus du développement socio-économique et démographique, ces graves problèmes se sont avérés difficiles à contrôler et ont entraîné une destruction importante des mangroves.

Aujourd'hui, toute la population subit les conséquences de ce déséquilibre environnemental. Le mode de vie dans le delta du Mékong, fondé sur la pêche et l'agriculture, est lourdement menacé. La population dans le delta a doublé en 50 ans à la fin du siècle dernier, profitant de l'agriculture intensive du riz et de l'exploitation des bassins à crevettes et du poisson.

Ces impacts et conséquences de l'ordre naturel et environnemental conditionnent l'occupation du sol et le type de couverture terrestre. La mise en avant de ces conditions permettra une compréhension holistique de la dynamique de l'occupation du sol dans une optique d'une gestion spatiale efficace des enjeux socio-économiques.

1.2. Risque d'inondation dans le delta du Mékong

En ce début du XXI^{ème} siècle, le risque d'inondation constitue encore le risque majeur dans le monde (60 % des catastrophes naturelles) et il est susceptible de devenir encore plus grave dans le futur en raison du changement climatique et de la poursuite de l'urbanisation des zones côtières, rendues vulnérables par l'élévation du niveau de la mer (Hanson *et al.*, 2011). Les hypothèses sur le réchauffement climatique et ses conséquences font état de craintes concernant l'augmentation des phénomènes pluviométriques intenses, bien que de nombreuses incertitudes pèsent

encore sur la réponse pluviométrique au réchauffement (Vignet, 2010). Une aide très précieuse susceptible d'améliorer l'efficacité de ces analyses et des secours, est rendue par les actions de la *Charte Espace et catastrophes majeures*¹.

Dans le delta du Mékong, les inondations sont causées par les débits élevés du fleuve résultant de fortes pluies sur le bassin versant. Ces inondations sont aggravées par l'élévation du niveau de la mer (Gupta, 2009). Le changement climatique entraîne un déséquilibre du régime des précipitations, ce qui provoque des changements dans le cycle hydrologique. Combiné au réchauffement qui a des impacts directs sur l'évapotranspiration, la génération de ruissellement peut être modifiée (Vörösmarty *et al.*, 2000). D'autre part, les activités anthropiques telles que les barrages et l'irrigation pourraient perturber le débit naturel des rivières et modifier les caractéristiques des régimes hydrologiques (Hall *et al.*, 2014).

Des études antérieures ont révélé, qu'au cours de la seconde moitié du vingtième siècle, le Mékong a connu une augmentation de la fréquence des crues extrêmes et une légère diminution de l'ampleur des crues, mais les changements sont plus complexes en raison des différences de mécanismes d'inondation dans le bassin (Delgado *et al.*, 2010).

En soit, les périodes de crues saisonnières dans le delta du Mékong, jouent un rôle essentiel en alimentant le delta en sédiments qui soutiennent la zone de production agricole. Cependant, selon une étude de (Wang *et al.*, 2017) le changement climatique intensifiera le risque d'inondation avec une fréquence plus élevée (10 %-140 %). Ainsi, les précipitations annuelles et l'intensité des précipitations extrêmes devraient toutes les deux augmenter. En d'autres termes, les impacts discernables du changement climatique provoquent des augmentations beaucoup plus importantes de la variation interannuelle, et par conséquent, une augmentation du pic et de la durée des inondations dans le Mékong (Västilä *et al.*, 2010) (Hirabayashi *et al.*, 2013). En effet, malgré l'incertitude dans la projection des précipitations, le réchauffement climatique déplace systématiquement plus tôt la date du pic des crues (Thompson *et al.*, 2014).

¹ Accord intervenu entre les agences spatiales participantes visant à fournir de l'information et des données obtenues de l'espace pour appuyer les efforts humanitaires lors de situations d'urgence causées par des catastrophes majeures.

1.2.1 La sécheresse

Les phénomènes climatiques sont également à l'origine de sécheresses de plus en plus graves. Le delta du Mékong est situé au centre de la région asiatique de la mousson tropicale qui apporte une chaleur et des précipitations abondantes. Les variations saisonnières et les changements interannuels importants entraînent des sécheresses fréquentes. Ceci est dû à l'évaporation élevée pendant la saison annuelle sèche (décembre à mai) qui impose des contraintes aux activités humaines dans le delta du Mékong. En effet, le manque de précipitations, la consommation excessive en eau des canaux d'eau et la construction des barrages sont à l'origine de la situation de sécheresse.

Même avec des périodes de sécheresse plus courtes, qui se produisent au début ou à la fin de la saison des pluies, il est possible qu'il y ait également des impacts extrêmement dommageables pour les cultures nouvellement plantées (Thuan, 2006).

En effet, la volonté gouvernementale s'est orientée vers le développement d'infrastructures visant à contrôler les systèmes hydrologiques, pour la gestion des ressources en eau dans le delta du Mékong. Cependant la régulation du débit des rivières par l'exploitation des barrages, propice au développement agricole, dans le bassin du Mékong a modifié les variations saisonnières extrêmes de l'approvisionnement en eau (Frenken, 2012). Ces gestions des ressources en eau ont créé de nouveaux problèmes environnementaux et ont conduit à des dépendances qui remettent en cause la capacité du système socio-écologique local à s'adapter aux changements climatiques (Brown *et al.*, 2018).

En outre, la réduction de l'apport en sédiments induite par le changement climatique et les barrages aurait probablement une influence significative sur l'agriculture et la pêche dans le delta du Mékong (Kondolf *et al.*, 2014). Par conséquent, l'altération du régime hydrologique due au changement climatique, à l'élévation du niveau de la mer et à l'exploitation des barrages existants et futurs entraînera des changements dans l'utilisation des terres dans la région du delta (Pokhrel *et al.*, 2018).

Durant l'année 2020, plus de 362 000 ha de rizières auraient été détruits, selon les estimations du gouvernement vietnamien, à cause du phénomène de la sécheresse qui affecte le delta du Mékong.

Selon un rapport du ministère des ressources naturelles et de l'environnement vietnamien, la température moyenne augmentera d'environ 1,5°C. Ainsi, les situations

de manque d'eau deviendront graves. Ce sont les conditions initiales de la sécheresse. Et si la sécheresse dure, ses impacts sur les secteurs socio-économiques seront plus grands et resteront plus longtemps (IMHEN, 2011).

1.2.2 L'intrusion des eaux salines

Les eaux salines pénètrent à l'intérieur des terres par les différents bras du Mékong et les canaux sur 20 à 65 km de la côte (Trung, 2006). La mer de Chine méridionale a une marée semi-diurne, c.à.d. deux pleines mers et deux basses mers par jour avec un marnage quotidien moyen entre 3,5 m et 4,5 m dans la mer de l'Est (NEDECO, 1993). Pendant la saison sèche, le débit principal du fleuve Mékong est assez faible et son niveau d'eau est bas. En outre, durant la pleine mer, l'eau saline s'infiltré profondément à l'intérieur des terres, sur une superficie de 500 000 ha sur toute la zone du delta du Mékong ce qui a de graves conséquences sur les rizicultures et les autres cultures (White, 2002).

Cependant, en raison de l'important apport d'eau douce par le Mékong, la salinité le long de la côte orientale du delta est très faible, en particulier pendant la saison des pluies. Vers la fin de la saison des pluies, la combinaison des eaux de crue des rivières, des précipitations locales et de l'effet des marées peut entraîner l'inondation de 3 400 000 hectares dans la partie du delta du Mékong (NIAPP, 2001) (Trung, 2006).

Chapitre 2. Le système du fleuve Rouge

Le système du fleuve Rouge, situé en Asie du Sud-Est, a un bassin versant total de 169 000 km² (Haruyama, 1995) avec une plaine deltaïque fertile et densément peuplée (densité de population de 962 habitants/km²). L'origine de son nom revient aux sols de latérite rouge qui sont abondants dans cette zone montagneuse (van Maren, 2007). Il prend sa source en Chine dans la zone montagneuse de la province du Yunnan, pour s'écouler sur 1 200 km en traversant sept provinces vietnamiennes avant de se jeter dans le golfe du Tonkin dans la mer de Chine méridionale (*Figure 3*).



Figure 3 : Le delta du fleuve Rouge au Vietnam

Cette région est caractérisée par un climat tropical de mousson avec une saison humide, de mai à octobre, et une saison sèche, de novembre à avril. La saison estivale est chaude et très humide, avec des températures moyennes allant de 27°C à 29°C, tandis que la saison hivernale est fraîche et sèche avec des températures mensuelles moyennes allant de 16°C à 21°C (Li *et al.*, 2006).

Dans le système du fleuve Rouge, 85 % à 95 % des précipitations sont abondants durant la saison estivale (Le *et al.*, 2007) de mai à octobre (saison des crues), avec des précipitations annuelles moyennes de 1 600 mm. Sur la base des enregistrements de 1960 à 2008, le régime hydrologique du fleuve Rouge est caractérisé par un régime tropical avec un rapport de débit mensuel moyen maximum/minimum de 7,9 (1 085 m³/s - 8 600 m³/s) et des débits journaliers extrêmes qui diffèrent d'un facteur 210 (160 m³/s - 33 600 m³/s) (Dang *et al.*, 2010).

La majorité de la population et de l'activité économique de la moitié nord du Viêt-Nam est concentrée dans le delta du fleuve Rouge et près de la moitié de la production de riz du pays y est cultivée. En effet, la production alimentaire dans le delta est principalement basée sur la récolte de riz durant la seconde moitié de l'année (Niculescu et Lam, 2019).

2.1. Type d'occupation du sol du delta du fleuve Rouge

La récente transition du pays vers une économie de marché a entraîné une augmentation des rendements suite à l'intensification des activités agricoles, ce qui a conduit à une plus grande vulnérabilité environnementale. Après une quarantaine d'années de libéralisation économique et d'ouverture du pays aux marchés internationaux, les modes d'utilisation des terres agricoles dans le delta du fleuve Rouge, et en particulier dans les zones côtières, ont subi de nombreux changements.

2.1.1 Les activités aquacoles

La production et la commercialisation des produits de l'aquaculture dans les zones côtières du Viêt-Nam sont des enjeux économiques très importants car elles ont permis, et permettent encore, une amélioration rapide des niveaux de revenus de la population locale. Cela inclut les paysans et les pêcheurs qui dépendent fortement des ressources naturelles de la zone côtière pour augmenter leur production. En effet, les mangroves et même les rizières sont remplacées par des champs d'aquaculture à un rythme sans précédent (Bergeret, 2004). Une partie importante de la zone côtière est actuellement couverte par des étangs d'aquaculture pour la culture de crevettes et de crabes, utilisant des méthodes tant industrielles que traditionnelles.

Ces changements d'affectation des sols, qui se traduisent par l'occupation de surfaces, de plus en plus grandes, par des bassins d'aquaculture, ont malheureusement contribué au déclin des forêts de mangroves, ces dernières étant un élément protecteur de la zone côtière. La pollution des eaux due aux effluents des déchets rejetés par les parcelles d'élevage, a augmenté.

2.1.2 Les activités agricoles

L'utilisation actuelle des terres dans la région côtière est orientée vers l'agriculture, avec le riz comme principale culture. Deux cultures de riz et une culture sèche sont produites par an (Do et Egashira, 2002) (patates douces, arachides, tabac, maïs, etc.). Dans certaines zones très basses, salées et récemment défrichées, on

cultive temporairement du scirpe pour améliorer la qualité du sol avant de le mettre en culture.

Au contraire, les zones résidentielles sont situées sur des terrains plus élevés, hors de portée des inondations. On y trouve des villages où ils alternent la culture des arbres à fruits et arbres d'ombrage comme le bananier, l'eucalyptus et le filao. Dans les zones côtières salines et les estuaires, la végétation se développe naturellement pour former des forêts. Cependant, la formation végétale prédominante est la forêt de palétuviers, principalement du type *Sonneratia*, avec une hauteur allant de 1 à 3,5 m. Dans certaines zones de haute altitude, le filao est cultivé pour la production de bois et pour la protection des villages de l'intérieur contre les tempêtes.

2.1.3 La législation et Gestion spatiale du delta du fleuve Rouge

Un changement dans la gestion des terres a eu lieu dans le cadre de la politique du « Doi Moi ». Une économie de marché a remplacé l'économie socialiste. En 1988, le décret n°10 dit « khoan 10 » a été adopté par le Bureau politique, marquant un net changement d'orientation économique et une large libéralisation du commerce privé. En effet, les agriculteurs ont obtenu des droits de propriété sur leurs terres. Même si l'État reste propriétaire de la terre, son utilisation privée est autorisée. Les agriculteurs ont donc obtenu des droits fonciers lorsque le système de planification de l'État a été aboli. Les impôts payés par les agriculteurs à l'État ont été réduits à 10 % et ce taux est resté inchangé pendant 5 ans, ce qui a rassuré les agriculteurs par rapport à la pérennité de leurs exploitations.

Le principe de l'attribution égalitaire des terres agricoles a été abandonné, celles-ci ont été attribuées en fonction de la capacité de production des agriculteurs et de la disponibilité des terres de la coopérative. La durée du bail pour les rizières, auparavant fixée entre 1 et 3 ans, a été portée à 20 ans. Le « paquet simplifié » a été remplacé par le « paquet net », qui permet aux agriculteurs d'être responsables de huit étapes de la culture du riz, au lieu des cinq étapes traditionnellement accordées. La majorité des taxes agricoles ont été réduites (baisse des prix des engrais chimiques, des insecticides et du carburant, suppression des impôts progressifs et d'autres taxes perçues par les autorités locales comme l'impôt sur le revenu ou la taxe de solidarité), ce qui a permis aux agriculteurs de réduire leurs coûts d'exploitation. Les agriculteurs ont également été autorisés à vendre leurs produits récoltés sur un marché libre, sans passer par une coopérative, car le ménage est depuis considéré comme une unité économique indépendante, et chaque agriculteur a donc pu bénéficier de sa propre

récolte. Ce décret est appliqué dans le sud du Viêt-Nam depuis 1988. Il n'est entré en vigueur que deux ans plus tard dans le nord du pays, où les dirigeants conservateurs, cherchant à conserver leur pouvoir et leurs privilèges, se sont opposés à toute forme de réforme de la gestion des terres.

Toutes ces législations ont conditionné les activités agricoles en termes d'expansion et de répartitions spatiales.

2.2. Impact des conditions climatiques sur le delta du fleuve Rouge

2.2.1 Risque d'inondation dans le delta du fleuve rouge

La région du delta du fleuve rouge connaît des inondations périodiques qui menacent les activités économiques en général et les activités agricoles en particulier, et qui fragilisent l'environnement. Les dernières grandes crues historiques de 1945 et 1971 et celle de 2001 ont causé d'importants dégâts et ont marqué la mémoire populaire. Ces événements ont causé d'importants dégâts matériels en provoquant des brèches dans certaines digues et par conséquent de grandes inondations de vastes zones réputées protégées.

En général, il y a eu moins de précipitations ces dernières années, mais elles se sont produites avec une plus grande intensité, ce qui entraîne un déséquilibre dans leur distribution tout au long de l'année. Par exemple, les précipitations annuelles en 1996 étaient de 1725 mm/an avec un pic mensuel de 360 mm/mois alors que celles de 2006 étaient de 1345 mm/an et 450 mm/mois (Luu *et al.*, 2010).

Ainsi la volonté des décideurs et des gestionnaires s'oriente vers une minimisation des inondations perçues comme l'aléa naturel physique à gérer. La solution se concrétise donc sous forme de mesures structurelles. En effet, des ouvrages de protection et des digues ont été implantés depuis des années. Ce sont d'ailleurs ces actions d'endiguement qui ont permis au delta d'accueillir une telle densité de population (Gilard, 2006) ainsi que des activités agricoles et aquacoles que la région connaît actuellement.

2.2.2 Intrusion des eaux salines

Les intrusions des eaux salines sont principalement dues aux marées hautes. Dans le Golfe du Tonkin la marée est de type diurne, avec un seul cycle (une marée descendante et une marée montante) par jour et une amplitude qui suit un cycle lunaire de 14 jours et diminue progressivement de 4 à 2 m du nord au sud (Fang *et al.*, 1999).

Le niveau de la marée à basse altitude, à l'embouchure de la branche principale du fleuve Rouge, varie de 0,5 m pendant les marées de mortes eaux à 2,5 m pendant les marées de vives eaux.

Pendant la saison des pluies, en raison de l'important débit d'eau douce provenant de l'amont, le problème de l'intrusion de la salinité ne se pose pas. Cependant, pendant la saison sèche, en raison du faible débit d'eau douce, l'intrusion de la salinité dans les estuaires des rivières est présente. L'intrusion des eaux salines est observée dans le delta jusqu'à 40 km vers l'intérieur des terres depuis les embouchures (Pham, 2004). Plus loin de la côte, l'influence de la marée sur le niveau d'eau et le débit est constatée, avec des variations quotidiennes du niveau d'eau pouvant atteindre 1 m pendant la saison sèche et 0,6 m pendant la saison des crues (Luu *et al.*, 2010).

En comparaison du delta du Mékong, l'intrusion de la salinité n'est pas aussi grave en raison de la pente relativement importante du lit du fleuve Rouge. Cependant, c'est une des zones le plus densément peuplée du Viêt-Nam et, par conséquent, le problème de la salinité n'est pas sans effets considérables sur l'environnement socio-économique (Ca *et al.*, 1994).

Chapitre 3. L'occupation du sol dans les deltas du Viêt-Nam

Les zones deltaïques sont des écosystèmes très productifs qui fournissent un moyen de subsistance aux populations locales, néanmoins elles sont considérées comme étant biologiquement et écologiquement complexes (Cosslett et Cosslett, 2014). Au Viêt-Nam, les évolutions actuelles du contexte, à la fois climatique, économique et sociétal, font de la gouvernance des changements de l'occupation des sols au niveau des systèmes deltaïques une question fondamentale. Le modèle de couverture des sols dans ces zones côtières/deltaïques, a changé de manière significative au cours des décennies (Sakamoto *et al.*, 2009) (voir titres 2.1 et 3.1).

Ce qui a affecté à la fois la croissance économique et la durabilité environnementale de la région. Dans ce contexte, le suivi et la détection du changement de l'occupation et de la couverture des sols (Land Use/Land Change) sont essentiels pour la planification et la gestion spatiale du territoire, notamment pour la conservation de l'éco-environnement et la planification spatiale dans les zones côtières.

3.1. L'étude de changement de l'occupation/couverture du sol

L'analyse du changement du type d'occupation du sol consiste à effectuer une extraction d'informations thématiques selon diverses classes à partir des données spatiales. En effet, les informations extraites à partir des données satellitaires peuvent jouer un rôle important en fournissant des éléments fondés sur des preuves concernant les changements dans ces zones.

L'analyse se base sur des données multi-date qui sont des sources d'information précieuses pour connaître la trajectoire du changement du type d'utilisation et de couverture des sols, tout en décelant les facteurs entraînant la destruction des écosystèmes, tels que l'expansion de l'aquaculture et l'agriculture en dépit du système naturel des deltas du Viêt-Nam.

Aujourd'hui, l'utilisation de données satellitaires et de méthodes de télédétection pour produire des cartes d'occupation du sol est en plein essor car elle offre des avantages en termes de rentabilité et de précision. En effet, de nombreuses études ont indiqué que la télédétection présente des avantages par rapport aux enquêtes traditionnelles sur le terrain pour l'étude de l'occupation du sol notamment des zones fragiles (mangrove, delta et zones côtières) en raison de la vue synoptique et de l'emprise de la couverture de ce type de données (Singh *et al.* 2010 ; Kuenzer *et al.* 2011 ; Avtar *et al.* 2017 ; Pham *et al.* 2019).

On note que dans le but de surveiller la distribution des écosystèmes naturels (mangroves, zone humide, forêts) et des zones urbaines (exemple : Singh *et al.* 2010 ; Vo *et al.* 2013 ; Avtar *et al.* 2017), plusieurs études ont été effectuées afin de suivre les changements de l'occupation du sol en se basant sur la télédétection dans le delta du Mékong, (Nguyen *et al.* 2016a, b ; Minh *et al.* 2019). En outre, dans le but de surveiller le mode de culture agricole, la majorité des études se sont concentrées sur la délimitation de la distribution des cultures de riz en utilisant des images satellites optiques (par exemple Sakamoto *et al.*, 2006 ; Son *et al.*, 2013 ; Kontgis *et al.*, 2015) et des images satellites radar (par exemple Liew *et al.*, 1998 ; Karila *et al.*, 2014 ; Nguyen *et al.*, 2016 ; Kontgis *et al.*, 2017, Minh *et al.* (2019).

Par ailleurs, plusieurs études ont été menées pour détecter l'expansion de l'élevage de crevettes à l'aide de la télédétection optique (Tong *et al.*, 2004 ; Sakamoto *et al.*, 2009 ; Vo *et al.*, 2013). Dans ce double sens agriculture-aquaculture, des études concernant les changements spatio-temporels des systèmes d'aquaculture intensive à l'aide de techniques de télédétection, telle que celle de Sakamoto *et al.* (2009), ont montré que l'aquaculture s'est rapidement développée, et que la proportion de riz à triple culture a diminué. Ce constat a été révélé grâce aux données satellitaires disponibles depuis 1972.

3.2. Les données satellitaires et la détection de l'occupation du sol

Dans les différentes études qui concernent la cartographie de l'occupation des deltas au Viêt-Nam, un assortiment de données satellitaires a été utilisé, notamment des données multi spectrales, du radar à synthèse d'ouverture (SAR), ainsi que des données hyperspectrales (exp. Pham *et al.* 2019). En effet, ces données issues de différents types de capteurs, Landsat (Tran *et al.*, 2015) SPOT (Stibig *et al.*, 2004) MODIS (Spruce *et al.*, 2020) et Sentinel (Pham *et al.*, 2021), ont prouvé leur utilité et efficacité dans le suivi du changement de l'occupation du sol.

Nous détaillons les propriétés de ces capteurs satellites, dont les données sont largement utilisées pour les études de l'occupation du sol dans les deltas du Viêt-Nam, dans le chapitre qui suit.

3.3. L'étude du risque d'inondation

Les inondations à travers le monde, sont parmi les catastrophes naturelles les plus destructives affectant, plus particulièrement, les terres basses, à l'instar des zones côtières. Les pays d'Asie du Sud-Est sont vulnérables aux inondations, notamment pendant la saison des pluies. Ainsi, ce risque constitue une des plus

grandes menaces du changement climatique dans les deltas du Viêt-Nam (Voir titres 2.2 et 3.2). Les impacts et la fréquence des inondations devraient augmenter à l'avenir en raison du développement urbain et du changement climatique (Kundzewicz *et al.*, 2014). En effet, des organisations telles que la Commission du Mékong et le Centre asiatique de préparation aux catastrophes mettent en œuvre des systèmes régionaux de prévision des inondations en combinant de manière synergique des données et des modèles hydrologiques (Ahmed *et al.*, 2017).

Les nouvelles avancées scientifiques et technologiques en matière de puissance de calcul, les modèles numériques de terrain, les algorithmes d'apprentissage automatique ou les données issues des satellites ont facilité et rendu possibles les études de ce risque à différentes échelles en faisant la différence entre l'échelle de l'inondation et celle du phénomène.

Les modèles hydrologiques et hydrauliques sont des outils précieux pour la gestion et la planification des risques d'inondation. Les sorties de ces modèles peuvent être couplées avec des extractions d'étendues d'eau basées sur la télédétection (Hong Quang *et al.*, 2020) pour améliorer la précision du modèle hydrologique, atténuer la pénurie de données et augmenter la rentabilité (Cian *et al.*, 2018).

3.3.1 Étude de l'occupation du sol pour l'évaluation du risque d'inondation

La production de cartes de couverture du sol est devenue un moyen fréquent et répandu et apparaît comme un indicateur clé pour le suivi des risques d'inondation (An Thi Ngoc Dang et Lalit Kumar, 2017 ; Mojaddadi *et al.*, 2017). En pratique, l'étendue de l'extension des eaux peut être estimée grâce à la détection du type de la couverture du sol, en faisant une extraction des informations via les images satellitaires. De fait, ces cartes peuvent être intégrées dans les bases de données sur les inondations pour réaliser un zonage des endroits à risque et déterminer la vulnérabilité au phénomène d'inondation.

Dans ce contexte, la cartographie de l'occupation du sol est un des éléments d'analyse du risque de l'inondation. Elle permet d'identifier les zones affectées par le phénomène en mettant en évidence les enjeux, les modifications de la couverture terrestre, ses causes et ses conséquences.

En effet, l'extraction du type d'occupation du sol permet d'identifier les enjeux qui peuvent être exposés aux risques d'inondation. Ainsi, en projetant les résultats du zonage des endroits à risque (les zones inondables) sur la carte d'occupation du sol, il serait possible d'estimer les dégâts et ainsi analyser la vulnérabilité face au risque

d'inondation. Dans le delta du Mékong, l'estimation des étendues d'eau (zonage) peut affecter les rizières qui constituent un enjeu économique incontournable pour le pays, touchées par les inondations, ces enjeux socio-économiques sont devenus vulnérables.

La cartographie de l'occupation du sol est une tâche essentielle pour la planification du développement, et pour la gestion des terres dans le monde entier, elle permet aux autorités et aux décideurs de mieux comprendre et de contrôler les impacts du risque d'inondation.

3.3.2 Les données satellitaires et l'évaluation du risque d'inondation

Les satellites sont maintenant devenus une composante essentielle de la gestion de l'environnement et des risques. Les capteurs actifs ou passifs utilisés pour des applications en matière de risque inondation couvrent un domaine très large du spectre électromagnétique et les informations issues de ces gammes spectrales ou de leur combinaison ont permis, au cours de ces dernières années, de contribuer de manière significative à la prévision et à la gestion du risque.

L'intégration de paramètres provenant des données d'observation de la Terre dans les **modèles hydrologiques** occupe une vaste place dans de nombreuses recherches. Les interactions entre certaines gammes de longueurs d'onde et divers paramètres biophysiques tels que l'humidité du sol (Jackson *et al.*, 2006 ; Neusch, 2000 ; Wagner *et al.*, 2007 ; Owe *et al.*, 2008), leur rugosité (Neusch, 2000 ; Straatsma, 2005 ; Rahman, 2007), la nature des couverts végétaux (Luquet *et al.*, 2001 ; Stiles *et al.*, 2000 ; Mertes *et al.*, 2004 ; Straatsma, 2005 ; Martin *et al.*, 2008) ont multiplié les recherches dans ce sens. Par exemple, la présence de l'eau, des lacs, des fleuves, des estuaires ou de la végétation inondée est bien détectée par le biais de micro-ondes actives, via le mécanisme de rétrodiffusion, avec des réponses très faibles pour la rétrodiffusion simple et des valeurs importantes dans le cas de double rebond (végétation inondée, Lewis, 1998; Hess *et al.*, 2003). Les radars multipolarisations et multifréquences sont également des outils pour la classification de la végétation des zones inondables en fonction des longueurs d'onde, de la polarisation et du mécanisme de rétrodiffusion associés à l'ampleur de l'inondation et de la taille de la végétation (Costa *et al.*, 2002 ; Ting *et al.*, 2015).

Le but est de développer des prévisions fiables des inondations. Pendant les dernières décennies, il y a eu des avancées majeures dans le domaine de la

téledétection, en particulier de la téledétection de micro-ondes, et de la modélisation des inondations.

La recherche récente sur l'intégration de la téledétection avec la modélisation des inondations étudie la modélisation de l'information hydrologique à partir de l'observation satellite (écoulement, extension des inondations et le niveau de l'eau), l'utilisation des données (informations) pour la calibration et la validation des modèles hydrodynamiques, le potentiel de la téledétection d'améliorer la structuration des modèles et la possibilité d'assimiler les observations satellites dans différents modèles. En général, les paramètres issus des traitements d'image qui sont assimilés dans des modèles hydrologiques sont : la lame d'eau précipitée, l'humidité et l'occupation du sol, le modèle et les caractéristiques du terrain.

Les images radar (SAR) représentent une source intéressante d'informations pour la surveillance des inondations et l'étude de l'humidité du sol. Après le lancement du satellite SAR, ENVISAT, les années 2006, 2007 représentent la deuxième période de lancement des satellites SAR avec le lancement de 5 missions pour l'observation de la terre par satellite radar sur trois bandes différentes : ALOS (bande L, Japon, 2006), TerraSAR-X (bande X, Allemagne, 2007), TanDem-X (bande X, Allemagne, 2010), RadarSAT-2 (bande C, Canada, 2007) et la constellation COSMO-SkyMed (bande X, Italie, 2007 jusqu'à 2010). Ces nouveaux capteurs offrent de nouvelles pistes de recherche, y compris des données de haute résolution spatiale (résolution métrique) ou de polarimétrie cohérente (intégralement) en matière de gestion des inondations et de développement durable.

Le système SAR mesure l'amplitude et la phase du signal rétrodiffusé en obtenant comme résultat une image complexe pour chaque enregistrement. En tenant compte de la répétitivité des enregistrements du satellite (orbite héliosynchrone), le traitement SAR multitemporel incohérent a ouvert la possibilité d'exploiter la dimension temporelle de la détection des changements incohérents (Rignot et van Zyl, 1993; Quegan *et al.*, 2000). Les méthodes semi-automatiques d'extraction du périmètre inondé en partant de la détection des changements incohérents ont été introduites pour la surveillance des zones inondables et leur cartographie (Takeuchi *et al.*, 1999; Andreoli et Yésou, 2008).

Une deuxième catégorie de données radar est représentée par les données InSAR interférométrie qui part de deux acquisitions d'images complexes (SLC) avec des angles d'enregistrement légèrement différents. Après l'enregistrement des deux images initiales, on calcule la corrélation croisée complexe normalisée. Sa magnitude,

appelée cohérence et sa phase sont les critères les plus connus en interférométrie SAR (Maître, 2001). La cohérence est utilisée dans la plupart des cas pour la description de la stabilité temporelle du signal acquis. Alors que la phase inclut une composante géométrique liée à la distance entre la cible et le capteur en donnant des informations sur l'altitude et le déplacement (éventuel) de la cible (Massonet et Rabaute, 1993, Massonet et Feigle, 1998). Afin d'éviter la phase de l'atmosphère, Ferreti *et al.* (2001) propose l'analyse de toute une série d'interférogrammes et la phase des pixels stables. Cette technique porte le nom de *Permanent Scatterer Technique*. A la base de cette analyse, c'est le choix des pixels en fonction de leur amplitude pour la mesure des déplacements. Dans le domaine de surveillance des inondations, le potentiel de l'interférométrie SAR a été démontré depuis les années 90 (Geutner *et al.*, 1996). Les cartes de cohérence interférométrique InSAR ont donné des informations utiles sur l'ampleur des inondations du fleuve Rhin.

Cependant, le traitement et l'analyse des données SAR multivariées est assez difficile. En comparaison avec les données optiques, les images complexes fournies par les Radar à ouverture synthétique (composées de pixels avec leurs amplitudes et leurs phases) se présentent sous différentes formes : interférométriques, polarimétriques, multitemporelles, à bandes multiples, etc. Les algorithmes de traitement des données multivariées considèrent l'image comme un processus aléatoire Gaussien homogène. Les systèmes SAR lancés actuellement (TerraSar-X, TanDem-X, COSMO-SkyMed, Sentinel-1) sont capables de fournir des images SAR de haute qualité en résolution spatiale métrique. La résolution spatiale plus fine est une réalisation importante par rapport aux images radar antérieures à résolution spatiale décamétriques, mais conduit en même temps à des effets plus compliqués tout comme l'hétérogénéité spatiale et le non-gaussienisme. Les techniques d'estimation, de classification, de détection des paramètres physiques, les filtres utilisés sur les images décamétriques doivent être adaptés au nouveau contexte de résolution spatiale métrique. Ainsi, certaines techniques ont été récemment proposées pour trouver des solutions à la segmentation hiérarchique (Bombrun *et al.*, 2011), à la classification polarimétrique (Froment *et al.*, 2011), au suivi et à l'analyse de la texture (Harant *et al.*, 2011).

Selon certains chercheurs (Vidal, 2005), pour être fiables, les modèles hydrauliques doivent être contraints, par le biais d'un calage, grâce à des connaissances concernant la crue (niveaux d'eau, volume transitant de la plaine au moment du passage de la crue, etc.). Selon d'autres auteurs (Aronica *et al.*, 1998 ;

Pappenberger *et al.*, 2005 ; Hostache *et al.*, 2006 ; 2010) ces données sont la plupart du temps difficiles à acquérir sur le terrain. Une solution peut être envisagée : l'exploitation des niveaux d'eau en période d'inondation estimés à partir d'images satellites radar. Des méthodes basées sur la mesure du coefficient de rétrodiffusion radar sur des données à haute résolution ont fait l'objet de développement en bande L (Ulaby *et al.*, 1983 ; Kim *et al.*, 2014 ; Chapman *et al.*, 2015) et en bande C (Fellah *et al.*, 1994, 2003 ; Brown *et al.*, 1997 ; Matgen *et al.*, 2007 ; Ramsey *et al.*, 2013) ; des niveaux d'eau ont été estimés par croisement entre des limites de zones inondées extraites d'images satellitaires radar toujours en bande C et des cartes topographiques (Brakenridge *et al.*, 1998 ; Hostache, 2009 ; Mason *et al.*, 2009, 2012). Les incertitudes obtenues (entre 1 à 3 m) ont été considérées comme incompatibles avec la précision requise par les modélisations hydrauliques. Pour améliorer l'extraction du rivage dans des secteurs où la végétation est inondée, Horrit *et al.* (2002) utilisent la taille de la végétation dérivée des données du LiDAR. Une approche similaire est développée par Puech et Raclot (2002) à partir de photographies aériennes, Hostache *et al.* (2006, 2009, 2010) appliquent une méthode de cartographie sur une image SAR en utilisant des données photogrammétriques de haute précision (incertitude de 30 cm en moyenne).

En utilisant les variations du coefficient de rétrodiffusion radar en fonction de la teneur en eau surfacique des sols, des suivis d'évolutions spatio-temporelles des zones saturées dans des bassins versants sont réalisés (Pauwels, 2001 ; Summerell, 2009). Ces variations spatio-temporelles de ***l'humidité du sol*** sont introduites dans différents modèles qui utilisent le couplage entre un indice topographique et un indice de saturation potentielle (Gineste *et al.*, 1998) ; des valeurs d'humidité globale utilisées à l'échelle du bassin versant (*Integrated Flood Forecast System*, Bach *et al.*, 1999). L'intégration des données de télédétection comme l'humidité du sol en modèles hydrologiques, bien que ces modèles ne soient pas encore opérationnels, a également fourni des résultats prometteurs dans plusieurs études (François *et al.*, 2003 ; Matgen *et al.*, 2006).

La phase de gestion de crise nécessite la production de documents cartographiques localisant l'événement et son étendue. Diverses méthodes existent pour obtenir le plan d'information des données spatiales : photo-interprétation, seuillage, segmentation d'image qui utilisent des principes mathématiques élaborés tels que la détection de contours, la logique floue avec le data mining ou les réseaux de neurones artificiels. Plusieurs techniques de traitements d'images SAR existent.

Ces techniques incluent : simple interprétation visuelle (Oberstadler *et al.*, 1997), seuillage d'histogrammes d'images (Brivio *et al.*, 2002 ; Matgen *et al.*, 2004), algorithme de classification automatique (Bonn et Dixon, 2005 ; Pulvirenti *et al.*, 2011 ; Kuenzer *et al.*, 2013 ; Niculescu *et al.*, 2009, 2015), algorithme de texture d'image (Schumann *et al.*, 2009), méthodes de détection multitemporelle de changements (Laugier *et al.*, 1997 ; Niculescu *et al.*, 2009, 2010 ; 2015 ; Martinis et Rieke, 2015). De nombreuses études (Marinelli *et al.*, 1997; Nico *et al.*, 2000 ; Yésou *et al.*, 2000 ; Alsdorf *et al.*, 2001) montrent l'apport important de la variation de cohérence de phase, obtenue à partir d'une paire interférométrique d'images radar, en complétant l'étude de l'amplitude du signal.

En revanche, la télédétection passive dépend de l'ensoleillement et elle est sensible aux conditions atmosphériques et aux couverts nuageux. Dans le contexte des études des inondations, la télédétection passive peut présenter une limite quand la couverture nuageuse est importante, ce qui est le cas en période de forte pluie et de crue. Cette limite constitue un réel obstacle pour l'étude des problèmes environnementaux, notamment dans les zones tropicales et équatoriales où la couverture nuageuse reste assez importante.

Les images optiques disponibles gratuitement, telles que Landsat (TM) peuvent être utiles pour l'analyse du risque grâce à leur résolution spatiale et leur intervalle d'acquisition, mais aussi grâce à l'archive et la capture continue sur les mêmes zones qui rendent ces données très pratiques pour la cartographie des masses d'eau. En effet, les données de la bande 7 de Landsat sont utiles pour distinguer les plans d'eau de la masse terrestre environnante, avec un taux d'erreur d'environ 5 % (Dhara *et al.*, 2020). Bien que les données Landsat aient une résolution spatiale relativement plus élevée que les données MODIS, leur temps de revisite est plus long que celui du MODIS. Ces derniers comprennent deux instruments clés, les satellites Terra et Aqua. Terra MODIS capture des images de la surface de la terre tous les jours ou tous les deux jours, et acquiert des données dans 36 bandes spectrales (Ticehurst *et al.*, 2014; Revilla-Romero *et al.*, 2015) ce qui reste très pratique pour la cartographie des zones inondables. Par ailleurs, des images optiques Sentinel-2 A et B, ont également été utilisées dans plusieurs études des risques d'inondation.

Chapitre 4. Satellites Landsat et Sentinel

4.1. Le satellite Landsat

Parmi les divers programmes d'observation de la terre, les missions Landsat (connue au début sous l'acronyme ERTS-1 (*Earth Resources Technology Satellite*)), de l'agence spatiale américaine (NASA) (plus tard sous la responsabilité de National Oceanic et Atmospheric Administration-NOAA) sont les plus réputées. En effet, grâce à la couverture mondiale continue depuis 1972 à une moyenne résolution (le plus long enregistrement continu) ainsi qu'à leur diffusion gratuite, les données Landsat ont été couramment utilisées pour la détection des changements de l'occupation du sol (Liu *et al.*, 2020).

Il faut noter aussi que parmi les facteurs qui ont contribué au succès technique des données Landsat c'est la combinaison de capteurs avec des domaines spectraux façonnés pour l'observation de la Terre, ce qui est efficace dans une grande variété de contextes d'application. Par ailleurs, le programme a permis d'accumuler des archives de données volumineuses et de maintenir des données historiques. Ces données historiques sont une exigence fondamentale pour la surveillance de l'environnement afin de prévenir les impacts environnementaux néfastes avant qu'ils ne deviennent irréparables (Manandhar *et al.*, 2009). Entre 1972 et 2013, huit satellites Landsat sont lancés, permettant de capturer plusieurs millions d'images. L'archive de ces données est fournie par le Centre national d'observation et de science des ressources terrestres (USGS EROS) du Service géologique des États-Unis.

Les satellites Landsat portent des capteurs de type systèmes de caméras *Return Beam Vidicon* (RBV), le système *Multi Spectral Scanner* (MSS), et dernièrement le *Thematic Mapper* (TM). Avec un balayeur qui utilise un miroir oscillant, le MSS capte le rayonnement électromagnétique de la surface de la Terre provenant de quatre bandes spectrales. Chacune de ces bandes a une résolution radiométrique de 6 octets et une résolution spatiale de 60 sur 80 mètres. Depuis le lancement du Landsat-4, le capteur TM a remplacé le MSS, en apportant plusieurs améliorations (une meilleure résolution spatiale et radiométrique, sept bandes spectrales plus étroites par rapport aux quatre bandes du MSS). Chacune des bandes a une résolution radiométrique de 8 octets, ainsi, sauf pour l'infrarouge thermique qui est de 120 m, toutes les autres bandes ont une résolution spatiale de 30 m. Certes leurs archives les plus riches leur procurent un grand avantage, mais la résolution spatiale des images limite leur exploitation dans tous les domaines.

Le satellite Landsat-8, une collaboration entre la NASA et l'*United States Geological Survey* (USGS), a été lancé en février 2013. Il couvre la Terre tous les 16 jours avec des images de 185 km x 185 km, en 16 bits, comptant 11 bandes spectrales : 9 dans le visible (8 multispectrales de résolution 30 m ; 1 panchromatique à 15 m) et 2 thermiques (60 m). L'équipement de télédétection installé sur le LCDM (*Landsat Data Continuity Mission*) comprend un radiomètre à balayage multicanaux OLI (*Operational Land Imager*) et un radiomètre IR à deux canaux TIRS (*Thermal Infrared Sensor*). L'imageur terrestre opérationnel (OLI) offre deux nouvelles bandes spectrales par rapport à l'instrument Landsat-7 ETM+, l'une spécialement conçue pour la détection des cirrus (bande 9, nouvelle bande proche infrarouge (NIR)) et l'autre pour l'observation des zones côtières (bande 1, nouveau canal bleu dans le visible). Il mesure dans les parties visibles, NIR et infrarouge à ondes courtes (SWIR) du spectre électromagnétique et offre une résolution spatiale panchromatique de 15 mètres et multi spectrale de 30 mètres. Le capteur infrarouge thermique (TIRS) a été ajouté à la charge utile de Landsat 8 afin de poursuivre l'imagerie thermique et de prendre en charge des applications émergentes telles que les mesures du taux d'évapotranspiration pour la gestion de l'eau. Le TIRS a été construit par le *Goddard Space Flight Center* de la NASA, et sa durée de vie est de trois ans. Les données TIRS de 100 m sont enregistrées avec les données OLI pour créer des produits de données Landsat-8 de 12 bits corrigés sur le plan radiométrique, géométrique et du terrain. Les images des satellites LANDSAT sont libres de droit et diffusées par le *US Geological Survey* (USGS). Dans nos applications les images Landsat 8 (OLI) sont utilisées pour l'analyse et la cartographie des changements de l'occupation du sol dans le delta du fleuve Rouge.

4.2. La constellation Sentinel

L'ESA (l'Agence spatiale européenne) développe une nouvelle famille de missions appelée « Sentinel » spécifiquement pour les besoins opérationnels du programme Copernicus. Chaque mission Sentinel s'appuie sur une constellation de deux satellites pour répondre aux exigences de revisite et de couverture, fournissant des ensembles de données robustes pour les services Copernicus.

L'objectif du programme Sentinel est de remplacer les anciennes missions d'observation de la Terre qui sont en fin de leur durée de vie opérationnelle, comme les missions ERS et Envisat. Cela permettra d'assurer une continuité des données afin qu'il n'y ait pas de lacunes dans les études en cours. Chaque mission se concentre sur un aspect différent de l'observation de la Terre, à savoir la surveillance de

l'atmosphère, des océans et des terres, et les données recueillies sont utiles dans de nombreuses applications. Les missions Sentinel embarquent une gamme de technologies telles que des instruments radar et d'imagerie multi-spectrale. En effet, la mission Sentinel-1 (Sentinel-1A et Sentinel-1B) embarque une technologie radar en orbite polaire, jour et nuit, destinée aux services terrestres et océaniques. Sentinel-1A a été lancé le 3 avril 2014 et Sentinel-1B le 25 avril 2016. Sentinel-2 (Sentinel-2A et Sentinel-2B) est une mission d'imagerie multi-spectrale haute résolution en orbite polaire pour la surveillance des terres. Elle fournit, par exemple, des images de la végétation, de la couverture du sol et de l'eau, des voies navigables intérieures et des zones côtières. Sentinel-2 peut également fournir des informations aux services d'urgence. Sentinel-2A a été lancé le 23 juin 2015 et Sentinel-2B a suivi le 7 mars 2017. Sentinel-3 (Sentinel-3A et Sentinel-3B) est une mission multi-instruments qui soutient les systèmes de prévision océanique, ainsi que la surveillance de l'environnement et du climat. Elle vise à mesurer la topographie de la surface de la mer, la température de la surface de la mer et de la terre, la couleur de l'océan et de la terre avec une précision et une fiabilité de haut niveau. Il existe d'autres missions à divers objectifs opérationnels comme le Sentinel-4 et le Sentinel-5 qui sont une charge consacrée à la surveillance de l'atmosphère, ainsi que le Sentinel-6 qui a été mis en orbite le 21 novembre 2020, il transporte un altimètre radar pour mesurer la hauteur de la surface de la mer à l'échelle mondiale, principalement pour l'océanographie opérationnelle et les études climatiques.

Dans notre contexte d'étude, les images du capteur Sentinel-1 (SAR) et Sentinel-2 (équipé d'un instrument multi-spectral, MSI) sont les plus utilisées. Sentinel-1 offre une amélioration significative de la couverture spectrale, de la résolution spatiale et de la fréquence temporelle par rapport à la génération actuelle de capteurs Landsat. Pour la cartographie de l'occupation/utilisation des sols, Sentinel-2 est particulièrement pertinent en raison de la présence de deux nouvelles bandes dans le spectre de la bordure rouge, à 705 et 740 nm.

Par ailleurs, des études ont testé la capacité du Sentinel-1 (SAR) dans le delta du Mékong ce qui a été particulièrement pertinent pour cette région tropicale, car les capacités tout temps du SAR permettent de faire face à la fréquente couverture nuageuse qui rend la télédétection optique difficile. En effet, le SAR joue un rôle crucial dans la télédétection en raison de sa capacité de pénétration des nuages et de détection (Bouvet et Le Toan, 2011).

En outre, Sentinel-1 est le seul satellite SAR disponible gratuitement et constitue donc une ressource précieuse pour les pays équatoriaux à revenus faibles et moyens dont les budgets pour l'achat de données satellitaires sont limités.

Partie 2 : Démarches Méthodologiques

Chapitre 5. Structuration des données et Prétraitement

5.1. Les images SAR : Sentinel-1

Dans ce travail, nous avons utilisé des données SAR de Sentinel-1. Avant la présentation de ces données, une explication du système radar s'avère nécessaire.

5.1.1 Les équations de radar

RADAR (*RA*dio *D*etection *A*nd *R*anging) est un système d'observation actif. Un système radar se compose essentiellement d'un émetteur, d'un récepteur, d'une antenne et d'un système électronique pour traiter et enregistrer les données. L'énergie électromagnétique se propage à la vitesse de la lumière, vers un objet ou une surface. Le radar mesure l'énergie de l'impulsion radar qui est réfléchiée vers le radar et est exprimée en rétrodiffusion radar (σ^0). Les objets peuvent être détectés en mesurant le délai entre l'émission d'une impulsion et la réception de « l'écho » rétrodiffusé de différentes cibles, ce qui fournit les informations sur l'amplitude, la phase, l'intervalle de temps entre l'émission de l'impulsion et le retour de l'objet, la polarisation et la fréquence Doppler.

La mesure de rétrodiffusion radar est exprimée par l'équation radar. Cette équation décrit la relation entre la puissance reçue (P_r) de l'onde électromagnétique reçue (\vec{E}^r) et la puissance émise (P_e) pour une seule cible sous la forme de l'onde émise (\vec{E}^e) et peut s'écrire :

$$P_r = P_e \frac{G^2 \lambda^2 \sigma}{(4\pi)^3 R^4} \quad (1)$$

Avec :

- G : le gain de l'antenne reçue
- λ : la Longueur d'onde
- R : la distance entre le cible et radar
- σ : la Surface Equivalente Radar, qui représente le rapport moyen entre l'énergie réémise par la cible dans la direction du radar et la densité d'énergie qu'elle reçoit. Elle est donnée par la formule :

$$\sigma = 4\pi R^2 \frac{|\vec{E}^r|^2}{|\vec{E}^e|^2} = 4\pi |S|^2 \quad (2)$$

$|\vec{E}^r|^2$ et $|\vec{E}^e|^2$ représentent de l'intensité de l'onde reçue et de l'onde émise.

$|S|^2$: l'amplitude de diffusion complexe de l'objet.

De nombreux radars sont conçus pour transmettre un rayonnement micro-ondes polarisé horizontalement (H) ou verticalement (V) (Figure 4). Une onde émise dans l'une ou l'autre de ces polarisations peut générer une onde rétrodiffusée avec une variété de polarisations. C'est l'analyse de ces combinaisons de polarisation à l'émission et à la réception qui constitue la science de la polarimétrie radar.




Figure 4 : Polarisation horizontale (noire) et verticale (rouge) d'une onde électromagnétique plane

L'onde électromagnétique (\vec{E}^e) est émise par une source en deux polarisations V et H puis l'onde reçue (\vec{E}^r) est diffusée par une cible. Les deux ondes sont décomposées comme suit :

$$\vec{E}^e = [E_H^e \ E_V^e] \vec{E}^r = [E_H^r \ E_V^r] \quad (3)$$

Grâce à la formule (2), une relation entre l'onde émise \vec{E}^e et l'onde reçue \vec{E}^r est donnée par :

$$\vec{E}^r = \frac{\exp(-\frac{i2\pi r}{\lambda})}{r} \cdot |S| \cdot \vec{E}^e \quad (4)$$

En remplaçant des vecteurs de formule (3) par la formule (4) et une décomposition $|S|$, la matrice de rétrodiffusion est donnée pour définir le processus de transformation de l'onde (\vec{E}^e) en une onde réfléchie (\vec{E}^r). Elle est définie comme suit : (Cloude et Zebker, 2010 ; Lee et Pottier, 2009).

$$[E_H^r \ E_V^r] = \frac{\exp(-\frac{i2\pi r}{\lambda})}{r} \cdot [S_{HH} \ S_{HV} \ S_{VH} \ S_{VV}] [E_H^e \ E_V^e] \quad (5)$$

Les ondes radars sont caractérisées par deux paramètres : la fréquence de fonctionnement, souvent exprimée en GigaHertz (GHz), et l'état de polarisation. Par convention, le champ électrique est pris comme référence pour déterminer l'état de polarisation défini par la forme de la courbe décrite, en fonction du temps, par la projection de l'extrémité du champ électrique dans le plan transverse de propagation (Frédéric Baup, 2007).

Toute polarisation à l'émission ou à la réception peut être synthétisée en utilisant les composantes H et V avec une relation bien définie entre elles. C'est pourquoi on utilise couramment des systèmes qui émettent et reçoivent ces deux polarisations linéaires. Avec ces radars, il peut y avoir quatre polarisations combinées en émission et en réception :

- HH - pour horizontale émise et horizontale reçue.
- VV - pour verticale émise et verticale reçue.
- HV - pour horizontale émise et verticale reçue.
- VH - pour verticale émise et horizontale reçue.

Les systèmes Radars peuvent avoir deux ou quatre polarisations combinées. Il y a plusieurs types de système radar (*Tableau 1*)

Tableau 1 : Polarisation utilisées

Nom	Des polarisations combinées
Polarisation simple	HH ou VV ou HV ou VH
Polarisation double	HH et HV, VV et VH, ou HH et VV
Polarisation alternée	HH et HV, alternant avec VV et VH
Polarimétries	HH, VV, HV, et VH

a) Rétrodiffusion directe de surface provenant du sol ; b) rétrodiffusion volumique provenant du feuillage des arbres, arbustes et de la litière végétale si présente ; c) rétrodiffusion directe de surface provenant de tiges, de branches principales, de troncs ; d) rétrodiffusion double-bond provenant de l'interaction entre les troncs et les autres composantes ; e) rétrodiffusion multiple provenant de l'interaction du signal incident avec plusieurs composantes.

5.1.2 Les images SAR

Un radar à synthèse d'ouverture (**SAR / Synthetic aperture radar**) est un radar d'imagerie monté sur une plate-forme mobile : un avion, un drone ou un satellite. Comme dans le cas d'un radar conventionnel, des ondes électromagnétiques sont émises séquentiellement et les échos rétrodiffusés sont recueillis par l'antenne radar. Dans le cas du SAR, le temps consécutif de transmission/réception se traduit par des positions différentes en raison du mouvement de la plate-forme. Une combinaison cohérente appropriée des signaux reçus permet la construction d'une ouverture virtuelle qui est beaucoup plus longue que la longueur physique de l'antenne. Cet attribut fondamental du SAR est à l'origine de son nom « ouverture synthétique », qui lui confère la propriété d'être une image radar.

5.1.3 Les images Sentinel-1

Dans ce travail, les données Sentinel-1 GDR sont utilisées pour l'étude et la détection du type de l'occupation du sol. La série temporelle de Sentinel-1 offre une opportunité unique de surveiller systématiquement les occupations du sol à un cycle de répétition hebdomadaire. En outre, la continuité des données Sentinel-1 est garantie jusqu'en 2030. Plusieurs études (ex. Abdikan *et al.*, 2016; Balzter *et al.*, 2015; Lee et Pottier, 2009; Longepe *et al.*, 2011) ont pu démontrer les différents avantages des données SAR.

Les données Sentinel-1 sont distribuées par le *Copernicus Open Access Hub* et comprennent :

- Niveau-0 ou Level-0 : les données brutes.
- Niveau-1 ou Level-1 : deux types de données de niveau 1.
 - **Single Look Complex** (SLC) : ce sont des données comprenant une imagerie complexe avec amplitude et phase.
 - **Ground Range Detected** (GRD) avec l'intensité **multi-look**.

- Niveau-2 ou Level-2 : **Ocean** (OCN) : ce sont des données pour la détection des paramètres géophysiques de l'océan.

L'instrument radar à ouverture synthétique (SAR) Sentinel-1 peut acquérir des données dans quatre modes qui sont illustrés dans la *Figure 5* et *Tableau 2*.




Figure 5 : Les modes du système Sentinel 1

Tableau 2 : Modes de système Sentinel-1

Mode	Swath (km)	Résolution (m×m)	Polarization
Stripmap	80	5×5	Dual
Extra WS	20	5×5	Dual
Interferometric IWS	250	5×20	Dual
Wave	400	20×40	Single

Un processus générique standard pour prétraiter les images SAR-level01-GRD de Copernicus Sentinel-1 est présenté dans les travaux de Filipponi et al (2019) (Filipponi, 2019). Le processus de prétraitement des images Sentinel-1 (*Figure 6*) est effectué par une plateforme SNAP (***Sentinel application Platform***) qui est développée pour servir les traitements des données de ESA (des images sentinel-1, sentinel-2). Dans ces études, les graphes de prétraitement des données sentinel-1 GDR permettent de traiter des images à l'aide du cadre de traitement et de graphe de commande, qui donnent la capacité de traitement de grands jeux de données.

Dans un graphe, le début du processus consiste à utiliser des fonctions qui permettent de lire les images et d'enregistrer des résultats. Ainsi, les fonctions qui permettent de traiter les signaux sont mis en ordre sériel ou parallèle. Dans nos études, les fonctions utilisées sont :

5.1.3.1 *Calibration* : les corrections radiométriques.

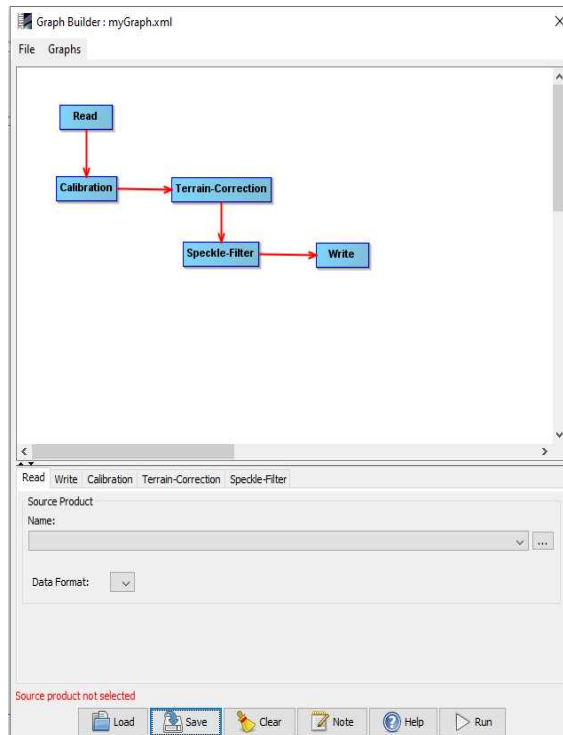


Figure 6 : Graphe de prétraitement des images Sentinel-1 à servir de détecter des occupations du sol dans le delta du Mékong

L'étalonnage (Calibration) est la procédure consistant à convertir les valeurs numériques des pixels en rétrodiffusion SAR étalonnée radio métriquement. Les informations nécessaires à l'application de l'équation d'étalonnage sont incluses dans le produit Sentinel-1 GRD ; en particulier, un vecteur d'étalonnage inclus comme annotation dans le produit permet une conversion simple des valeurs d'intensité de l'image en valeurs sigma zéro. L'étalonnage inverse le facteur d'échelle appliqué pendant la génération du produit de niveau 1, et applique un décalage constant et un gain dépendant de la plage, y compris la constante d'étalonnage absolue.

Le sigma spécifie l'intensité de la réflexion en termes de section géométrique traversée d'une sphère conductrice, et représente la section transversale radar d'une cible distribuée par rapport à celle attendue d'une surface d'un mètre carré. Le sigma zéro a une variation significative avec l'angle d'incidence, la longueur d'onde et la polarisation, ainsi qu'avec les propriétés de la surface de diffusion.

5.1.3.2 *Correction de terrain: les corrections géométriques.*

Les données SAR sont généralement captées avec un angle de vue variable supérieur à 0 degré, ce qui donne des images présentant une certaine distorsion liée à la géométrie de l'orientation latérale. Les corrections de terrain visent à compenser ces distorsions afin que la représentation géométrique de l'image soit aussi proche que possible du monde réel. La correction de terrain Doppler à distance est une correction des distorsions géométriques causées par la topographie, telles que le raccourcissement et les ombres, en utilisant un modèle numérique d'élévation pour corriger l'emplacement de chaque pixel. L'opérateur de correction de terrain par effet **Range Doppler** met en œuvre la méthode d'ortho rectification (Schubert *et al.*, 2015) pour le géocodage de scènes SAR à partir d'images en géométrie radar.

Le système de références des coordonnées (CRS) peut être sélectionné et, en option, réglé pour correspondre à la zone UTM des granules Sentinel-2. L'opérateur permet de sélectionner la méthode de rééchantillonnage de l'image et l'espacement des pixels dans le CRS cible. Cette étape de traitement permet l'accrochage spatial des produits Sentinel-1 GRD aux grilles de données MSI de Sentinel-2, afin de géolocaliser les données sur une grille spatiale commune et de promouvoir l'utilisation de constellations de satellites sentinel-1A et Sentinel-1B.

5.1.3.3 *Speckle filter : Les corrections des bruits.*

Le **Speckle**, qui apparaît dans les images SAR comme un bruit granulaire, est dû à l'interférence des ondes réfléchies par de nombreux diffuseurs élémentaires (Lee *et al.*, 1994a). Le **Speckle filter** est une procédure qui permet d'améliorer la qualité de l'image en réduisant le *Speckle* (bruit). Lorsqu'une telle procédure est effectuée à un stade précoce du traitement des données SAR, le *Speckle* n'est pas propagé dans les processus en cours (c'est-à-dire, **Correction de terrain** ou conversion en dB). Le *Speckle filter* n'est pas conseillé lorsqu'il s'agit d'identifier de petites structures spatiales ou la texture de l'image, car il risque de supprimer ces informations. Le filtre de Lee raffiné s'est avéré plus efficace, comparant aux autres *Speckle filter* à produit unique, pour l'interprétation visuelle, en raison de sa capacité à préserver les bords, les caractéristiques linéaires, les cibles ponctuelles et les informations de texture (Lee *et al.*, 1994b). Plus récemment, des *Speckle filter* de séries temporelles ont été développés pour réduire le bruit (*Speckle*), en tirant parti des multi-observations SAR dans le temps. L'outil SNAP met à disposition plusieurs filtres de *Speckle* : 'Boxcar', 'Median', 'Frost', 'Gamma Map', 'Lee', 'Refined Lee', 'Lee Sigma', 'IDAN'.

5.1.3.4 Conversion to décibel (dB) : les transformations logarithmiques dB.

En général, le processus de prétraitement effectue une série de corrections standard. Pour les corrections radiométriques, les corrections géométriques, les corrections des bruits, et comme dernière étape du processus de prétraitement, le coefficient de rétrodiffusion sans unité une conversion en dB est utilisée par une transformation logarithmique.

De plus, les produits Sentinel-1 GRD peuvent être de données MSI de Sentinel-2, afin de promouvoir l'utilisation de constellations virtuelles de satellites par le biais de la fusion de données. Dans le processus de prétraitement on peut inclure la fusion des données SAR avec des données optiques.

5.2. Les images optiques : Sentinel-2

Les données multispectrales de Sentinel-2 sont de haute résolution. Elles ont été utilisées dans les applications de ce travail. Les instruments d'imagerie multi-spectrale (MSI) de Sentinel-2 possèdent 13 bandes dont quatre bandes à 10 m, six bandes à 20 m et trois bandes à 60 m de résolution spatiale (*Tableau 3*) et une fauchée de 290 km.

Tableau 3 : Récapitulatif des résolutions spectrale, spatiale et temporelle de Sentinel 2

Sentinel-2													
Bandes	B1	B2	B3	B4	B5	B6	B7	B8	B8a	B9	B10	B11	B12
Centre λ (nm)	443	490	560	665	705	740	783	842	865	945	1375	1610	2190
Largeur λ (nm)	20	65	35	30	15	15	20	115	20	20	30	90	180
Résolution spatiale (m)	60	10	10	10	20	20	20	10	20	60	60	20	20
Résolution temporelle	5 jours												

Les images Sentinel-2 sont mises à disposition « prêtes à l'emploi ». Plusieurs niveaux de correction sont disponibles lors des téléchargements des images. Les

principaux niveaux disponibles pour notre zone d'étude sont de niveau 1C (le niveau 1C fournit des images ortho rectifiées) et 2A.

5.3. Les données de série temporelle

5.3.1 Les données optiques de série temporelle

La cartographie de l'occupation du sol est essentielle pour la gestion des forêts, la déforestation, l'agriculture et la planification. L'imagerie optique est un outil courant pour la classification simple de la couverture terrestre et la surveillance de la végétation. (Gong *et al.*, 2013; Kavitha *et al.*, 2021). Cependant, dans les zones à couverture terrestre complexe, il est difficile de cartographier plusieurs classes qui possèdent des similarités spectrales. C'est pourquoi les séries temporelles d'images optiques par satellite à basse et moyenne résolution (par exemple Landsat, Sentinel) ont été largement utilisées pour la surveillance de la végétation depuis les années 1970 (Zhang *et al.*, 2003). Dans notre travail, une application des modèles de données optiques de série temporelle est utilisée pour cartographier la végétation au delta du Fleuve Rouge de 2016 à 2018 (Niculescu et Lam, 2019). Les données de ce travail sont organisées en trois jeux de données : Data 2016, Data 2017, Data 2018 (*Tableau 4*). Pour obtenir plus d'informations, les capteurs Landsat-8 et Sentinel-2 sont combinés et mis en ordre dans un jeu de données.

5.3.2 Les données radars de série temporelle

Les images de séries temporelles fournies par les satellites Sentinel-2 offrent une opportunité unique pour la cartographie de la végétation (Mercier *et al.*, 2019). Le satellite Sentinel-2, a un temps de revisite de trois jours et une résolution spatiale de 10 mètres. Cependant, l'acquisition d'images optiques au cours des périodes clés de surveillance peut être limitée en raison de leur vulnérabilité au temps pluvieux ou nuageux. Dans ce contexte, le radar à synthèse d'ouverture, indépendant de l'illumination solaire et de la couverture nuageuse, est une forme de télédétection active. Le radar à synthèse d'ouverture (SAR) peut être utilisé comme une importante source de données alternative ou complémentaire (Bovenga, 2020; Moreira *et al.*, 2013; Schmullius et Evans, 1997; Tomiyasu, 1978). Les systèmes SAR enregistrent l'amplitude et la phase du signal rétrodiffusé, qui dépend des propriétés physiques et électriques de l'objet imagé (par exemple, la rugosité du terrain, la permittivité). Récemment, l'imagerie SAR série temporelle en bande C a été étudiée pour la surveillance de la végétation (Dobrinić *et al.*, 2020; Phan, 2018). Dans cette thèse, on

a étudié les inondations en 2019, 2020 dans le delta du Mékong à l'aide des données Sentinel-1 - SAR de série temporelle. Des jeux de données sont construits pour deux saisons (inondation et non-inondation) chaque année. Une carte de l'occupation du sol va être construite avec le jeu de données Non-inondation (de décembre à mai). Et les cartes de l'inondation vont être extraites des jeux de données de chaque mois qui sont dans la période d'inondation de juin à novembre (*Tableau 5*).

Tableau 4 : Séries temporelles 2016, 2017,2018 au delta du fleuve Rouge.

Jeux de données	Les capteurs	Date	Les bandes
Data 2016	Landsat-8	23/04/2016	B2,B3,B4,B5,NDVI
	Sentinel-2	15/06/2016	B2,B3,B4,B8, NDVI
	Landsat-8	26/06/2016	B2,B3,B4,B5,NDVI
	Landsat-8	30/09/2016	B2,B3,B4,B5,NDVI
Data 2017	Sentinel-2	04/21/2017	B2,B3,B4,B8, NDVI
	Sentinel-2	07/30/2017	B2,B3,B4,B8, NDVI
	Landsat-8	09/17/2017	B2,B3,B4,B5, NDVI
	Sentinel-2	12/17/2017	B2,B3,B4,B8, NDVI
Data 2018	Sentinel-2	11/02/2018	B2,B3,B4,B8, NDVI
	Sentinel-2	07/05/2018	B2,B3,B4,B8, NDVI
	Sentinel-2	06/20/2018	B2,B3,B4,B8, NDVI
	Sentinel-2	05/26/2018	B2,B3,B4,B8, NDVI

5.3.1 Synergie des données Optiques et RADARS

Récemment, l'intégration des données SAR et optiques (c.-à-d. Sentinel-1 et Sentinel-2) a été principalement utilisée pour la surveillance des inondations et des zones humides, la cartographie des perturbations forestières ou la cartographie de végétation (Dobrinić *et al.*, 2021; Ienco *et al.*, 2019; Niculescu *et al.*, 2018). Les séries temporelles d'images S1 et S2 offrent un grand potentiel pour la surveillance de la végétation, et cette recherche a étudié le potentiel des données S1, S2 et combinées S1 et S2 pour la cartographie de la végétation (Dobrinić *et al.*, 2020; Mercier *et al.*, 2019). Les séries temporelles SAR de Sentinel-1 ont été combinées avec l'imagerie de Sentinel-2, montrant qu'une amélioration de la précision de la classification peut être obtenue par rapport aux résultats obtenus avec chaque capteur indépendamment (Dobrinić *et al.*, 2021).

Tableau 5 : Organisation des jeux de données SAR de série temporelle au delta du Mékong en 2019-2020.

Saison	Sous-jeux de données	Les images
Non-inondation	Décembre à mai	30 images – 60 bandes de double polarisation VV-VH
inondation	Juin	Chaque mois 5 images – 20 bandes de double polarisation VV-VH
	Juillet	
	Août	
	Novembre	
	Octobre	
	Novembre	

Chapitre 6. *Machine Learning* (Apprentissage automatique)

L'intelligence artificielle (IA) consiste à rendre les machines aussi intelligentes que le cerveau humain. En informatique, l'IA désigne l'étude des « agents intelligents » : tout dispositif qui perçoit son environnement et entreprend des actions qui maximisent les chances de réussite pour atteindre ses objectifs. De manière informelle, le terme « intelligence artificielle » est appliqué lorsqu'une machine est capable d'exécuter des fonctions que les humains associent à d'esprits humains, comme « l'apprentissage » et « la résolution de problèmes ». L'apprentissage est un aspect essentiel des machines. Par conséquent, l'apprentissage automatique (*machine learning*) est un sous-domaine de l'IA *Figure 7*. Les informaticiens ont déployé des efforts depuis les années 1950 dans le domaine de l'apprentissage automatique. Depuis quelques décennies, des efforts considérables sont réalisés pour faire progresser l'apprentissage automatique. Cela conduit à des attentes plus élevées de la part des machines. L'apprentissage profond est une tentative dans cette direction. L'apprentissage profond (*Deep learning*) est un sous-domaine de l'apprentissage automatique (*Figure 7*) qui structure les algorithmes en couches pour créer un réseau neuronal artificiel capable d'apprendre et de prendre des décisions intelligentes par lui-même. Comme le travail dans l'apprentissage est mis en avant dans de nombreux nouveaux domaines et l'applicabilité des nouveaux domaines est toujours une tâche en cours dans la communauté de recherche.

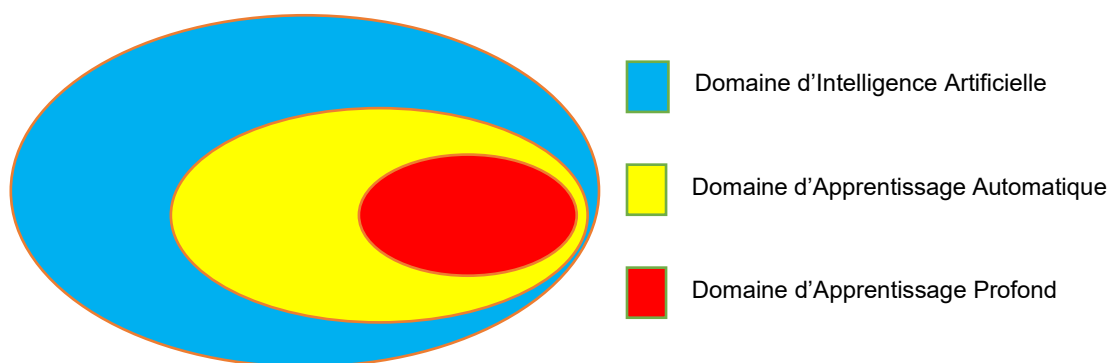


Figure 7 : Illustration des relations entre apprentissage automatique et apprentissage profond

6.1. Définition Apprentissage Automatique

Selon Tom M. Mitchell (1997) la définition de l'apprentissage automatique est: « ***A computer program is said to learn from experience E with respect to some class of tasks T et performance measure P, if its performance at tasks in T, as measured by P, improves with experience E.*** » (Mitchell, 1997)

Sur la base des mappages sous-jacents entre les données d'entrée et les résultats attendus présentés pendant la phase d'apprentissage de l'apprentissage automatique, les algorithmes d'apprentissage automatique peuvent être classés dans six catégories (Awad et Khanna, 2015) : l'apprentissage supervisé, l'apprentissage non-supervisé, l'apprentissage semi-supervisé, la méthodologie d'apprentissage par renforcement, l'apprentissage transductif, l'inférence inductive. Les algorithmes d'apprentissage automatique fréquemment appliqués dans les recherches de télédétection appartiennent à deux catégories d'algorithmes : l'apprentissage supervisé et l'apprentissage non-supervisé. L'efficacité de l'application de ces algorithmes a été largement prouvée dans les recherches (Blaschke *et al.*, 2014; Hay et Castilla, 2008; Lary *et al.*, 2016).

L'algorithme d'apprentissage supervisé (*Figure 8*) est une méthode d'apprentissage qui déduit la relation sous-jacente entre les données observées (également appelées données d'entrée) et une variable cible (une variable dépendante ou étiquette) qui est soumise à la prédiction. La tâche d'apprentissage utilise les données de formation étiquetées (exemples de formation) pour synthétiser la fonction du modèle qui tente de généraliser la relation sous-jacente entre les vecteurs de caractéristiques (entrée) et les signaux de supervision (sortie). Depuis 1970, les algorithmes d'apprentissage supervisé se sont appliqués à servir des travaux d'analyse des images satellites et ils jouent un rôle important dans la télédétection jusqu'à maintenant (Kettig et Landgrebe, 1976; MacQueen, 1967). Les algorithmes d'apprentissage supervisé sont souvent utilisés pour faire des classifications des composants géographiques dans les données d'images de télédétection (par pixel ou par objet).

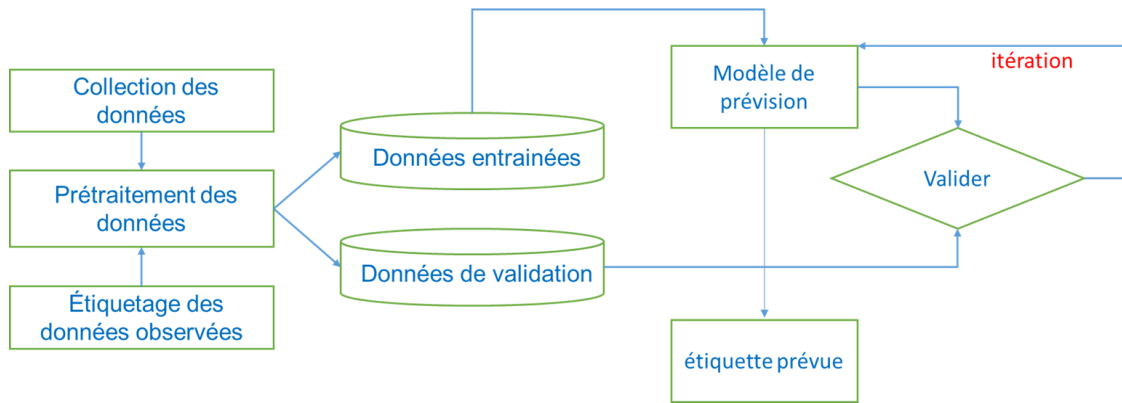


Figure 8 : Le processus général de l'algorithme d'apprentissage supervisé

Les algorithmes d'apprentissage non supervisé sont conçus pour découvrir des structures cachées dans des ensembles de données non étiquetés, dans lesquels la sortie souhaitée est inconnue. Deux exemples populaires d'apprentissage non supervisé sont le **regroupement (cluster)** et la réduction de la dimensionnalité. Dans le domaine de la télédétection, les apprentissages non-supervisés sont utilisés pour réaliser des Segmentations afin d'extraire des objets géographiques (Blaschke, 2010; Gu *et al.*, 2015; Schiewe, 2012)

6.2. Définition Apprentissage Profond

Les performances des méthodes d'apprentissage automatique dépendent de la représentation des données (ou des caractéristiques des données) sur laquelle elles sont appliquées. C'est pourquoi une grande partie de l'effort réel de déploiement des algorithmes d'apprentissage automatique est consacrée à la conception de prétraitement et de transformations de données qui aboutissent à une représentation des données capable de supporter un apprentissage automatique efficace (Bengio et al., 2014). Les méthodes d'apprentissage profond sont des méthodes d'apprentissage par représentation avec plusieurs niveaux de représentation, obtenus en composant des modules simples mais non linéaires qui transforment chacun la représentation à un niveau (en commençant par l'entrée brute) en une représentation à un niveau supérieur, légèrement plus abstrait. La composition d'un nombre suffisant de transformations de ce type permet d'apprendre des fonctions très complexes (LeCun et al., 2015). L'apprentissage profond s'est caractérisé par des réseaux neuronaux (NN) comportant généralement plus de deux couches cachées (c'est pour cette raison qu'ils sont appelés profonds). Comme les réseaux neuronaux peu profonds, les réseaux profonds exploitent des représentations de caractéristiques apprises exclusivement à partir de données. Il existe des modèles d'apprentissage automatique qui peuvent être appliqués sur le domaine de la télédétection comme :

Multilayer perceptron, Convolution Neural Network, Auto-Encoder (Zhu et al., 2017). Dans cette thèse, le **Convolutional neural network** est appliqué pour détecter de l'occupation du sol au delta du Mékong au Viêt-Nam. On a utilisé le modèle AlexNet – Réseau de neurones convolutifs entièrement connecté (FCN - *Figure 9*)

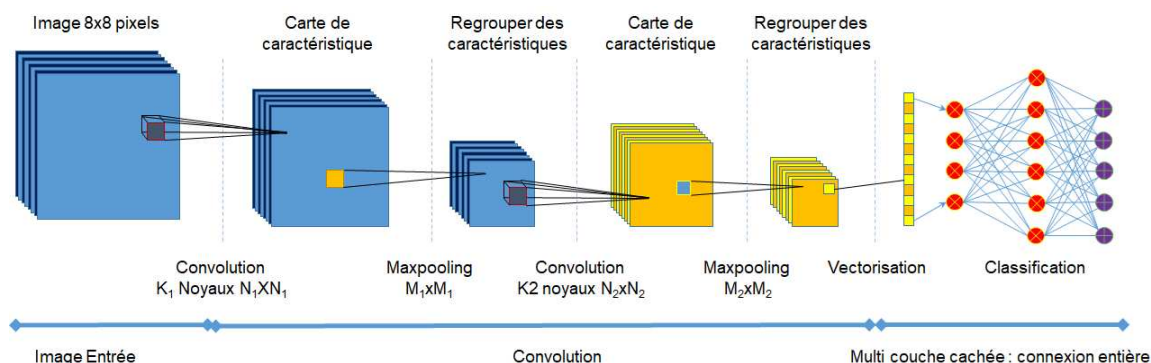


Figure 9 : L'architecture globale du Convolutional neural network (CNN) comprend une couche d'entrée, plusieurs couches de convolution et de max-pooling alternées, une couche entièrement connectée et une couche de classification.

6.3. La segmentation des images satellites

En 1976, Kettig et Landgrebe ont appliqué des segmentations sur des images satellites par des extractions et des classifications des objets homogènes (Kettig et Landgrebe, 1976). Par la suite, des techniques de traitement des images satellites ont été développées. Il y a plusieurs travaux qui ont tenté d'appliquer des techniques de segmentation d'images pour des applications en télédétection. Après l'arrivée des images de haute résolution, des algorithmes de segmentation ont été développés de manière significative (Blaschke, 2010; Schiewe, 2012). La plupart des travaux antérieurs ont catégorisé la segmentation d'image en 3 approches : basée contour, basée région, basée clustering.

6.3.1 L'algorithme K-means

L'algorithme K-means a été proposé la première fois en 1967 par (MacQueen, 1967). C'est une méthode non-supervisée dans le domaine d'apprentissage automatique. K-means aide à détecter des objets homogènes par les groupes de pixels voisins. Des éléments sont regroupés en K – partitions par des fonctions de similarité comme la distance euclidienne, la distance de Manhattan, etc. Avec le développement de GEOBIA, K-means est appliqué pour l'extraction d'objets afin d'aboutir à une analyse efficace des images satellitaires (Hamada *et al.*, 2019 ; Rezik *et al.*, 2006).

La fonction de similarité, c'est un facteur important dans le processus de l'algorithme K-means. Elle est représentée par le calcul de distance entre les objets avec N-dimension. La distance euclidienne est souvent utilisée dans ces calculs.

La distance de Minkowski :

$$Dist(x, y) = \sqrt[p]{\sum_{i=1}^n (x_i - y_i)^p} \quad (6)$$

La distance Euclidienne :

$$Dist(x, y) = \sqrt{\sum_{i=1}^n (x_i - y_i)^2} \quad (7)$$

La distance Manhattan :

$$Dist(x, y) = \sum_{i=1}^n \|x_i - y_i\| \quad (8)$$

L'Algorithme K-means est composé de deux phases de calcul distinctes. La première phase concerne le calcul des centroïdes pour K-groupe et la seconde phase concerne la mise à jour des pixels dans le groupe qui a le plus proche centroïde par rapport à la distance euclidienne. Par la réitération de la 1^{ère} phase, le processus continue jusqu'à l'étape de stabilité.

Avec un ensemble des groupes = $\{C_1, C_2, \dots, C_k\}$, chaque C_i à un centroïde μ_i , le calcul de l'optimisation est donné par :

$$\sum \sum_{x_i \in C_i} Dist(x_i, \mu_i)^2 \quad (9)$$

Les résultats ne sont pas uniques après chaque exécution. Cela dépend des centroïdes initiaux. Il existe plusieurs approches pour collecter les centroïdes, à savoir des approches de points aléatoires, des points stratifiés, des points d'incertitude, la densité de probabilité (Catlett, 1991 ; Khan et Ahmad, 2004 ; Lewis et Catlett, 1994).

Une question importante dans le cas de l'application de l'algorithme Kmeans sur un échantillon est le nombre de clusters K. Par principe, la méthode du « coude » est une heuristique utilisée pour déterminer le nombre de clusters K dans un échantillon.

La méthode consiste à tracer la variation expliquée en fonction du nombre de clusters, et à choisir « le coude » de la courbe comme le nombre de clusters à utiliser.

Initialiser le nombre de groupes et ses centroïdes

Calculer des distances entre les centroïdes et les pixels.

Attribuer tous les pixels au groupe qui a le centroïde le plus proche

Recalculer les centroïdes pour chaque groupe.

Calculer taux erreur E:

Répéter 2^e étape jusqu'à un résultat stable.

Extraire des objets géographiques par des pixels voisins

La variance des clusters se calcule comme suit :

$$variance = \sum_{i=1}^K \sum_{x_j} Dist(x_j, c_i)^2 \quad (10)$$

Avec :

c_i : Le centre du cluster (le centroïde)

x_j : la j ème observation dans le cluster ayant pour centroïde c_i

$Dist(x_j, c_i)$: La distance (euclidienne ou autre) entre le centre du cluster et le point x_j

On obtient une courbe :




Figure 10 : Le courbe des clusters k de 1 à 9, le coude est trouvé par K = 3

6.3.1.1 *Les avantages de K-means :*

La complexité de K-Means est présentée en : $O(K * n * d)$. Il est facile d'implémenter K-means et d'identifier des groupes de données inconnus à partir d'ensembles de données complexes. Les K-Means produisent des segmentations plus serrées.

K-means convient à un grand nombre d'ensembles de données et le calcul est beaucoup plus rapide par rapport à celui des autres algorithmes. Il peut également produire un nombre de clusters plus élevés. Cet algorithme permet de partitionner de grandes séries de données. Cependant, son efficacité dépend de la forme des clusters.

6.3.1.2 *Les inconvénients de K-means :*

Le clustering K-means donne des résultats variables sur différentes exécutions. En effet, un choix aléatoire de modèles de clusters produit différents résultats, ce qui entraîne une incohérence.

Pour que la classification par K-means soit efficace, il est nécessaire de spécifier le nombre de clusters (au début de l'exécution de l'algorithme). Il est également difficile de comparer la qualité des clusters produits.

Dans le cas d'étude et afin de fixer la bonne valeur du K, une expérimentation a été effectuée. Nous remarquons que les segmentations génèrent de temps en temps des zones homogènes. Le point de coude est trouvé par un $k=5$ et les résultats sont stables après ce point (*Figure 10*). La figure 11 présente un extrait d'une image Sentinel-2, nous présentons dans la *Figure 12* les résultats de la segmentation avec différente valeur de K, nous notons qu'avec un $k=10$ la segmentation donne un meilleur aperçu, préférable pour cette étape.

6.3.2 *Meanshift*

L'algorithme Meanshift de (Fukunaga et Hostetler, 1975) est un algorithme de regroupement robuste et adaptatif avec une estimation de densité de la probabilité non paramétrique. Cet algorithme ne nécessite pas de connaissance a priori du nombre de clusters. Il peut décaler les pixels vers les maxima locaux de la fonction de densité par des itérations efficaces en réalisant une convergence rapide. Ainsi, il a été utilisé avec succès dans la segmentation d'images par (Comaniciu *et al.*, 2001; Yang *et al.*, 2013; Zhou *et al.*, 2013).



Figure 11 : Image optique Sentinel-2 sur TranDe au 20 février 2020




Figure 12 : Kmeans (A) K=5 , (B) K=10 , (C) K=15

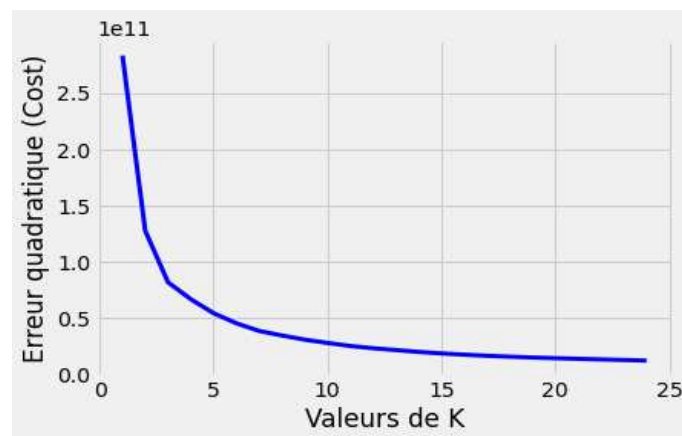


Figure 13 : La courbe des clusters k de 1 à 25

6.3.2.1 L'algorithme MeanShift présente deux étapes :

La recherche d'un ensemble des noyaux multi-variés par des fonctions des densités de probabilité Gaussien sur des informations spatiales et des signaux (Demirović, 2019; Michel *et al.*, 2015).

$$K(x) = \frac{C}{h_s^2 h_r^p} k\left(\left\|\frac{x^s}{h_s}\right\|^2\right) k\left(\left\|\frac{x^r}{h_r}\right\|^2\right) \quad (11)$$

Avec :

Multi variables (x^s, x^r) et multi-bande de passante (h_s, h_r)

Informations spatiales :

- Bande passante (bandwidth): h_s
- Des coordonnées spatiales : x^s

Informations signaux (des bandes) :

- Bande passante (bandwidth): h_r
- Des bandes d'image satellite: x^r

Le regroupement des pixels autour des noyaux les plus proches (maximum probabilité).

6.3.2.2 *Les avantages de MeanShift*

Cet algorithme ne fait aucune hypothèse de modèle et il est capable de modéliser des clusters complexes ayant une forme non convexe. Bien que cela n'implique pas toutes les formes, ces dernières peuvent être bien modélisées. L'utilisation d'un seul paramètre, la bande passante, détermine automatiquement le nombre de clusters qui a une signification d'échelle locale. Par ailleurs, cet algorithme n'a pas de minima local, donc le nombre de cluster est déterminé uniquement par la bande passante. Il ne nécessite pas une exécution des algorithmes d'initialisation du nombre ou des centroïdes de clusters (Carreira-Perpiñán, 2015).

6.3.2.3 *Les inconvénients de MeanShift*

La qualité des résultats dépend de la bande passante. Cependant, dans les travaux de (Comaniciu *et al.*, 2001; Dai *et al.*, 2014; Singh et Ahuja, 2002), on trouve des solutions représentatives au problème de la sélection de la bande passante. Ainsi, dans quelques cas (zones non homogènes), l'algorithme MeanShift génère des sous-clusters dans un grand cluster. Par ailleurs, les calculs sont lents et complexes.

La complexité de Meanshift est calculée par la formule $O(Tn^2)$, où T est le nombre d'itérations et n est le nombre total de pixels d'une image.

Une application de l'algorithme Meanshift a été effectuée pour segmenter des images Sentinel-2, avec différentes valeurs de K (*Figure 13*). Dans la *Figure 14*, nous

constatons qu'il y a des objets qui ne changent pas, c'est-à-dire qu'ils sont convergents. En outre, une segmentation sous forme de grands objets a été constatée dans la *Figure 14(C)* et en revanche, des objets de taille plus fine sont révélés dans les figures *Figure 14(A)* et *Figure 14(B)*. A ce niveau on se pose la question : « quelle est la meilleure bande pour la segmentation pour chaque image satellite ? »




Figure 14 : Segmentation de MeanShift avec la bande passante (A) $K = (16,32)$, (B) $K = (05,15)$, (C) $K = (03,05)$

6.3.3 Multi-résolution Segmentation (MRS)

La segmentation multi-résolution (MRS) (Batz et Schape, 2000) est probablement l'algorithme le plus populaire dans le domaine de segmentation. Implémenté dans le logiciel eCognition® (*Trimble Geospatial Imaging*), cet algorithme est rapidement devenu l'un des algorithmes de segmentation les plus importants de la discipline GEOBIA. MRS s'appuie sur un contrôle clé, appelé paramètre d'échelle (SP) pour partitionner une image en objets image. Le paramètre d'échelle contrôle l'hétérogénéité interne (spectrale) des objets d'image (*Figure 15*), il est corrélé à leur taille moyenne. Une valeur plus grande du SP permet une hétérogénéité interne plus élevée, ce qui augmente le nombre de pixels par objet (Batz et Schape, 2000; Benz et al., 2004).

L'objectif de l'algorithme MRS est de fusionner des objets d'une image, de sorte que l'objet soit précédé d'un pixel. À chaque étape, une paire d'objets est fusionnée en un plus grand objet. La décision de la fusion dépend de la condition d'homogénéité qui représente la similarité des objets adjacents. A son tour, la possibilité d'une fusion des paires d'objets adjacents dépend du coût de la fusion qui doit être minimum. La procédure est arrêtée quand il n'y a plus de possibilité de fusion dans une itération.

Le coût de fusion est composé par des valeurs homogénéités de couleur H_{color} et de forme H_{shape} .

$$H_{diff} = w_{color} * H_{color} + (1 - w_{color})H_{shape} \quad (12)$$

L'hétérogénéité spectrale (h_{obj}) d'un objet est donnée par la somme des écarts-types (σ_i) des valeurs spectrales de chaque bande i multipliée par leur poids (w_i):

$$h_{obj} = \sum_{i=1}^{n_{bande}} w_i \sigma_i \quad (13)$$

Le coût de fusion de couleur (H_{color}) des objets 1 et 2 en objet fusionné, c'est la différence entre l'hétérogénéité spectrale d'objet fusionné et la somme de l'hétérogénéité spectrale de deux objets.

$$H_{color} = n_{meg} h_{meg} - (n_{obj1} h_{obj1} + n_{obj2} h_{obj2})$$

L'hétérogénéité compacité (h_{cpt}) d'un objet est composée par le nombre des pixels (n_{obj}) dans l'objet et son périmètre (l).

$$h_{cpt} = \frac{l}{\sqrt{n_{obj}}}$$

L'hétérogénéité douceur (h_{smooth}) d'un objet est composée par le nombre des pixels (n_{obj}) dans l'objet et le périmètre (b) de la boîte délimitant l'objet.

$$h_{smooth} = \frac{l}{b}$$

Le coût de fusion de forme (H_{shape}) est basé sur la somme des coûts de fusion de compacité et du lissage :

$$H_{shape} = w_{cpt} H_{cpt} + (1 - w_{cpt}) H_{smooth}$$

Où :

$$H_{cpt} = n_{meg} h_{cpt}^{meg} - (n_{obj1} h_{cpt}^{obj1} + n_{obj2} h_{cpt}^{obj2})$$

$$H_{smooth} = n_{meg} h_{smooth}^{meg} - (n_{obj1} h_{smooth}^{obj1} + n_{obj2} h_{smooth}^{obj2})$$

6.3.3.1 *Les avantages de segmentation par algorithme multi-résolution :*

La vitesse de calcul et de génération des objets est convenable, ce qui peut être considéré comme un point fort pour cet algorithme. En outre, bien que les paramètres soient choisis d'une manière subjective, ils sont appliqués objectivement à l'image entière. En effet, les objets sont représentés par multi-échelle en connexion hiérarchique.

6.3.3.2 Les inconvénients de MRS :

Les objets ne sont pas réels, il s'agit de rassemblements des pixels homogènes, et les objets réels sont fusionnés à cause de la confusion spectrale des bandes des images.

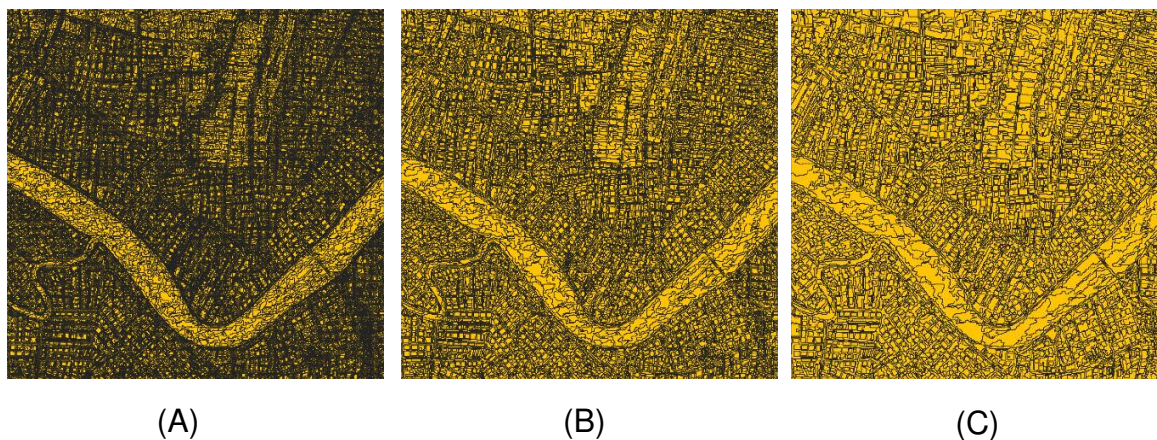


Figure 15 : Segmentation par multi résolution (A) Scale = 10, (B) Scale = 20 (C) Scale = 40

6.3.4 Superpixel (SLIC)

Le SLIC est un algorithme de segmentation basé sur le gradient ascendant, qui génère des superpixels. Il repose sur le principe de regroupement des pixels, en mesurant des distances, en fonction de leur proximité et de la similitude des couleurs dans le plan image (Achanta *et al.*, 2010). Dans le domaine de la télédétection, le SLIC a été utilisé dans une large gamme d'applications et de types de données, comme l'imagerie optique, les images SAR ou les images hyper spectrales (Arisoy et Kayabol, 2016; Fourie et Schoepfer, 2014; Ma *et al.*, 2016).

Parmi les différents algorithmes proposés pour générer des superpixels, SLIC se trouve sur la liste des algorithmes montrant des performances supérieures (Stutz *et al.*, 2018). Il présente des avantages en termes de simplicité, de vitesse de calcul et d'efficacité de la mémoire. C'est un algorithme basé sur le *clustering* inspiré d'autres méthodes telles que k-means initialisé par des centroïdes en utilisant des informations spectrales et spatiales. Les paramètres qui doivent être fixés pour l'exécution de SLIC sont le paramètre K, qui indique le nombre de superpixels à générer, et le paramètre m, qui contrôle la compacité des superpixels.

Avec le paramètre K et le nombre total des pixels N, la taille moyenne des superpixels $S \times S$ est calculée selon la formule suivante : $S = \sqrt{N/K}$

Nous présentons dans la *figure 16* un exemple d'application de l'algorithme avec différentes valeurs de S. Dans la première étape du SLIC, K initiales, et des centroïdes,

sur une grille carrée de taille $S \times S$ sont générés. Cette étape est construite selon l'algorithme K-Means. Une fois que tous les emplacements des centroïdes de cluster initiaux sont confirmés, une procédure itérative est appliquée pour mettre à jour les centres de cluster. La procédure itérative peut être répartie en trois étapes :

Etape 1 : Pour chaque centre de cluster, des distances D entre le centre du cluster et les pixels dans l'espace de recherche $2S \times 2S$ sont calculées avec une attribution à chaque pixel au centre le plus proche du cluster.

Etape 2 : C'est la mise à jour des nouveaux centres de cluster en calculant le vecteur moyen de tous les pixels appartenant au superpixel.

Etape 3 : L'erreur résiduelle E est calculée, c'est la distance entre les emplacements centraux précédents et les emplacements centraux mis à jour

La procédure itérative s'arrête lorsque l'erreur résiduelle converge ou le nombre d'itérations atteint le seuil défini (par exemple seuil = 10). Le résultat de cette procédure est un ensemble de centroïdes $C_K = [l_k, a_k, b_k, x_k, y_k]$ avec $k = \underline{1, K}$.

Dans SLIC, les informations de l'espace couleurs RGB sont remplacées par des informations couleurs CIELAB. La distance D est calculée par la composition de la distance de couleur avec la distance du spatial :

La distance couleur :

$$D_{lab} = \sqrt{(l_k - l_i)^2 + (a_k - a_i)^2 + (b_k - b_i)^2} \quad (14)$$

La distance spatiale :

$$D_{xy} = \sqrt{(x_k - x_i)^2 + (y_k - y_i)^2}$$

La distance entre un pixel avec une centroïde k :

$$D_S = D_{lab} + \frac{m}{S} D_{xy}$$

Plus la valeur de m est élevée, plus la proximité spatiale est accentuée et plus la grappe est compacte.

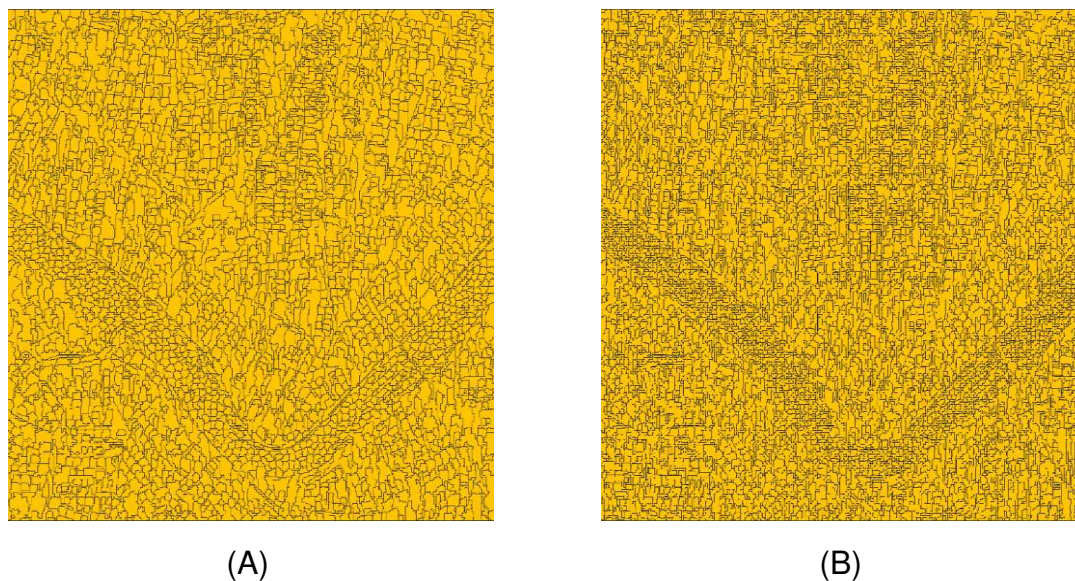


Figure 16 : Segmentations par SLIC avec la taille minimum (A) $S = 16$ pixels (B) $S=8$ pixels

La segmentation par l'algorithme SLIC passe par les étapes suivantes :

1 : Le calcul $C_K = [l_k, a_k, b_k, x_k, y_k]$ avec $k = \underline{1, K}$

2 : Les Itérations

- Pour chaque cluster C_k : les pixels les plus proches des centroïdes sont attribués en fonction des distances et à partir d'un voisinage carré $2S \times 2S$ autour du centre du cluster
- Le calcul des nouveaux centres de cluster et l'erreur résiduelle E
- L'itération s'arrête quand $E \leq$ au seuil donné

3 : Le regroupement des pixels dans un cluster et les extractions des objets GIS à partir des groupes de pixels.

6.4. Les méthodes de classification

Les informations de l'occupation du sol sont des éléments importants pour de nombreux aspects des études sur le changement global et des applications environnementales. L'une des principales approches pour obtenir des informations de l'occupation du sol à partir des images satellitaires est la classification. De nombreux algorithmes de classification ont été développés depuis l'acquisition de la première

image Landsat au début des années 1970. Parmi eux, on trouve les algorithmes d'apprentissage automatique peu profond (Machine Learning) comme la méthode de maximum de vraisemblance (Maximum Likelihood ML), les algorithmes de réseaux neuronaux (ex. *Multilayer Perceptron* MLP), des arbres de décision (ex. *Random forest*-RF) et l'algorithme de *Support Vector Machine* (SVM). Par ailleurs, suivant la tendance du développement des méthodes d'intelligence artificielle, plusieurs algorithmes d'apprentissage profond sont appliqués pour la classification des images (ex. *Convolutional neuron network* CNN).

Dans les sections qui suivent, le principe de chaque algorithme d'apprentissage automatique profond et peu profond, testé dans cette présente étude, est théoriquement et empiriquement décrit.

6.4.1 *Support Vector Machine* : SVM

L'apprentissage automatique par la méthode *Support Vector Machine* (SVM) a été développé par les recherches de Vapnik depuis 1965, pour devenir un algorithme en 1995 (Cortes et Vapnik, 1995). Selon plusieurs études (ex. (Foody et Mathur, 2004; Huang *et al.*, 2002)) le SVM est considéré comme un des meilleurs algorithmes dans le domaine de l'analyse d'images ; en effet, c'est un outil d'apprentissage automatique très populaire. Les classificateurs SVM sont initialement linéaires à deux classes, reposant sur la maximisation de la marge de séparation entre deux classes. Grâce aux fonctions de noyaux, des transformations sont désormais possibles pour une classification multi-classe.

6.4.1.1 *Support Vector Machine linéaire*

Le principe de (**SVM**) est basé sur la division, par un hyperplan séparateur, d'un ensemble en deux sous-ensembles marqués par des signes +1 ou -1. Il s'agit de déterminer un hyperplan optimal de façon à ce que la distance aux exemples d'apprentissage les plus proches (vecteurs de support) soit maximale. Cette distance est appelée "marge".

Un échantillon à n éléments est présenté par $S = \{(x_1, y_1), (x_2, y_2), \dots, (x_n, y_n)\}$. Dans un élément, $x_i \in R^k$, est un espace k -dimension et $y_i = \{+1, -1\}$ est l'étiquette de classe. SVM donne un vecteur support $w \in R^k$ pour trouver un hyperplan séparateur :

$$w \cdot x + b = 0$$

Deux hyperplans de support :

$$w \cdot x_i + b \geq +1 \text{ pour } y_i = +1$$

$$w \cdot x_i + b \leq -1 \text{ pour } y_i = -1$$

La marge, c'est la distance entre l'hyperplan séparateur et l'hyperplan supporteur :

$$marge = \frac{2}{\|w\|} = \frac{2}{\sqrt{\sum_{i=1}^k w_i^2}}$$

Un séparateur à vaste marge linéaire (SVM et support vector machine) est un discriminateur linéaire de la forme $predict = sign(w \cdot x + b)$ donné par la résolution du problème suivant :

$$\{\|w\|^2 \text{ Avec un Contrainte } y_i(w \cdot x_i + b) \geq 1$$

Dans le cas de données non séparables (Figure 17), il y a des erreurs ξ_i de classification. Des hyperplans supporteurs deviennent :

$$w \cdot x_i + b \geq +1 - \xi_i \text{ pour } y_i = +1$$

$$w \cdot x_i + b \leq -1 + \xi_i \text{ pour } y_i = -1$$

Avec $\forall \xi_i \geq 0$

Le problème peut alors prendre la forme suivante :

$$\{\|w\|^2 + c \sum \xi_i \text{ Avec une Contrainte } y_i(w \cdot x_i + b) \geq 1$$

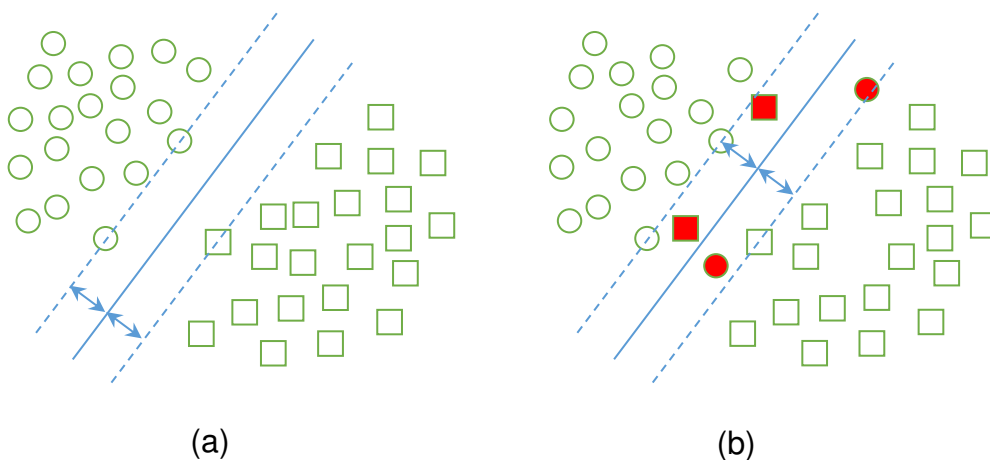


Figure 17 : Hyperplan de SVM (a) données séparables, (b) données non-séparables

Généralement, les données sont des espaces non linéaires (*Figure 18*). Des vecteurs supporteurs sont implémentés de façon à ce que les entrées x_i soient transformées par une fonction noyau $\Phi: R^k \rightarrow H$ qui projette les données dans un espace dans lequel elles seront considérées comme linéairement séparables (*Figure 18*). Ainsi, un nouveau SVM linéaires est appliqué sur le nouvel espace H.

La fonction noyau Φ est donnée par :

$$K(x_i, x_j) = \Phi(x_i)' \Phi(x_j)$$

Dans ce cas la fonction de prédiction est exprimée à l'aide de K et elle devient :

$$predict = sign(w \cdot K(x_i, x_j) + b)$$

Il existe plusieurs fonctions de noyaux utilisées (*Tableau 6*). L'exemple le plus simple de fonction noyau est le noyau linéaire. Par ailleurs, les noyaux les plus utilisés sont le noyau polynomial et le noyau gaussien.

- Un modèle SVM multi-classes

Un modèle SVM donne une capacité de discrimination d'un ensemble en deux classes. Dans le cas multi-classification, deux approches sont proposées.




Figure 18 : Hyperplan de SVM (a) données non-linéaires, (b) données transformées par noyaux polynomiales avec 2-degrés

6.4.1.1 L'approche un contre un (one-versus-one)

Sur chaque couple de classes, un classificateur SVM est construit. Un élément x_i est appliqué sur $\frac{n(n-1)}{2}$ modèle SVM, la classe gagnante est déterminée soit par un vote majoritaire « *max-wins voting* » soit en post traitement des résultats grâce à l'estimation de probabilités a posteriori.

Tableau 6 : Noyaux de SVM non linéaire.

Nom	Formule	Paramètres
Linéaire	$K(u, v) = u \cdot v$	
Polynomial	$K(u, v) = (\gamma \cdot u \cdot v + c)^d$	Le degré d et la gamma γ sont à préciser
<i>Radial basis fonction (RBF) Gaussien</i>	$K(u, v) = e^{-\gamma \ u-v\ ^2}$	Gamma γ à préciser
Sigmoïde	$K(u, v) = \tanh(\gamma \cdot u \cdot v + c)$	Gamma γ à préciser

Cette méthode est considérée plutôt pratique au-delà des arguments théoriques ou empiriques avancés pour sa bonne performance.

6.4.1.2 L'approche un contre tous (one-versus-all)

C'est la plus simple des méthodes de décomposition. Elle consiste à utiliser un classificateur SVM binaires (paires) par classe. Avec n classes, n modèles SVM, une attribution du label 1 à une des classes et le label -1 à toutes les autres s'effectuent.

Le classificateur donnant la marge la plus élevée remporte le vote « *winner-takes-all* » ainsi, la classe gagnante est trouvée. Il convient de souligner que cette approche soulève des difficultés pratiques, car elle implique d'effectuer des apprentissages aux répartitions entre catégories très déséquilibrées.

6.4.2 Random forest

L'analyse de l'occupation du sol basée sur des combinaisons d'informations hétérogènes provenant de multi-sources de télédétection, telles que des images optiques, des images radar, des informations d'élévation, est très efficace tout en apportant des défis aux méthodes d'apprentissage automatique (Gislason *et al.*, 2006; Lowe et Kulkarni, 2015; Rodriguez-Galiano *et al.*, 2012; Thanh Noi et Kappas, 2018). Ces auteurs ont démontré l'efficacité de la méthode de la forêt des arbres de décision (Figure 19) dans l'analyse des images de télédétection en provenant de multi-sources de capteurs.

Depuis les années 1980, les algorithmes d'arbre de décision ID3, CART, C45 ont prouvé leur efficacité en utilisant des données numériques et symboliques (Quinlan, 1986; Salzberg, 1994). Ces algorithmes donnent des résultats de bonne précision pour les données combinées multi-sources et hétérogènes. Afin de performer ces algorithmes d'arbre de décision et d'éliminer certains de leurs inconvénients (Breiman, 2001) a développé un algorithme appelé *Random forest*

construit à partir d'arbres de décision générés de sous-échantillons aléatoires en utilisant l'approche du *Bagging*.

Avant de présenter l'algorithme de *Random forest*, une présentation des deux principes servant à construire cet algorithme (les arbres de décision seuls et le *bagging*), est nécessaire.

6.4.2.1 *Arbre de décision seul*

L'arbre de décision est une structure hiérarchique générée par des fonctions statistiques et probabilistes. Le but du processus de construction d'arbres de décision est d'utiliser des règles de division et d'arrêt de calcul qui peuvent être partitionnées en ensembles d'éléments homogènes. L'algorithme de référence est celui de (Breiman, 1998) décrivant la méthode CART (*Classification et Regression Tree*). Néanmoins, la paternité de cette méthode est attribuée à (Morgan et Sonquist, 1963)

Le principe des arbres de décision repose sur la prédiction d'une classe en sortie après un processus de séparation successive des données. L'objectif est de prédire des groupes les plus homogènes possibles par rapport à la variable à prédire. La mise en place de cette méthode est considérée comme étant facile et rapide, mais elle peut être sensible à l'apprentissage exagéré.

6.4.2.2 *Le bagging (bootstrap aggregating)*

Inventé par (Breiman, 1996), le bagging est un méta-algorithme permettant d'améliorer la stabilité des algorithmes d'apprentissage automatique. Il permet de réduire les sources d'erreur liées à l'apprentissage exagéré (une limite que présentent les arbres de décision seuls). Le but est d'obtenir un modèle plus lisse à partir des différents modèles : c'est le principe de moyennage. En effet, à partir d'un ensemble d'entraînement A de taille n , le bagging produit m modèles d'entraînement A_i de taille n' . Ensuite, les m modèles produits sont calculés en utilisant les m sous-échantillons déjà calculés puis combinés par vote majoritaire (pour les classifications).

6.4.2.1 *La forêt des arbres de décision, (Random forest)*

La forêt des arbres de décision est un ensemble des classificateurs $H = \{H_1, H_2, \dots, H_k\}$ qui sont construits à partir des sous-échantillons aléatoires $E = \{E_1, E_2, \dots, E_k\}$

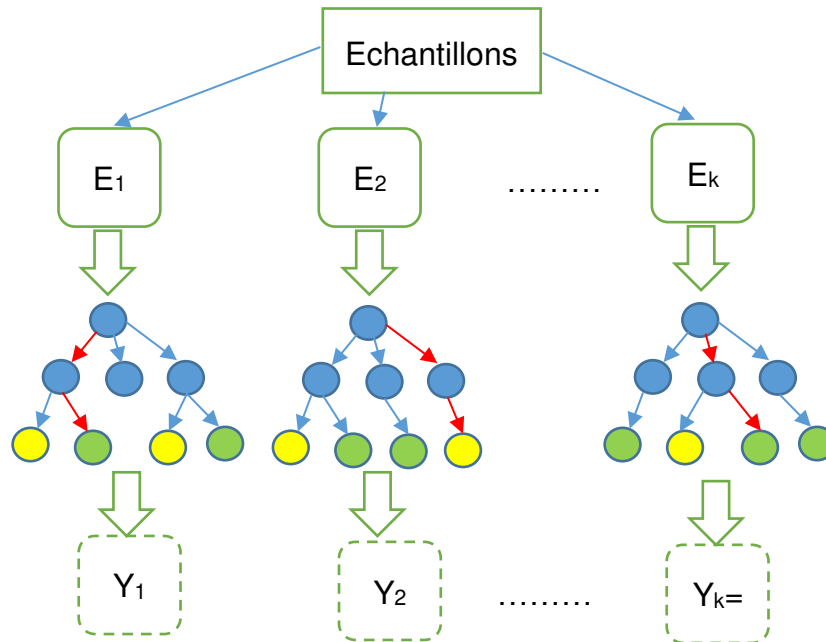


Figure 19 : Exemple de forêt d'arbres de décision

Dans l'étape d'entraînement :

- Un sous-échantillon est créé avec le nombre m d'éléments aléatoires. Le coefficient m est précisé.
- Pour chaque sous-échantillon, un arbre de décision est géré.
- Après k itérations, une forêt de k arbres de décisions est créée. Le coefficient m est précisé.

Dans l'étape d'application :

- Un élément x_i est appliqué sur tous les arbres dans la forêt, et la prévision de chaque arbre est sauvegardée.
- La dernière prévision est calculée par la fonction de vote majorité des résultats provenant des arbres de décision dans la forêt.

6.5. Méthodes de Deep Learning

6.5.1 Multilayer Perceptron – MLP

L'intelligence artificielle est un domaine de recherche qui pose des challenges et à laquelle les scientifiques se sont beaucoup intéressés. Dans ce domaine, le réseau de neurones a été proposé assez tôt dans les années 60. Le premier modèle de réseau de neurone est appelé **Perceptron**, c'est un algorithme d'apprentissage

automatique supervisé qui aide à résoudre les problèmes de la classification binaire. Il est proposé par (Rosenblatt, 1957).

Les réseaux de neurones sont modélisés en s'inspirant de la structure du cerveau humain, dans lesquelles l'intelligence est stockée dans les voies neuronales ainsi que dans la mémoire. Dans un réseau de neurones artificiels, les connaissances sont stockées sous forme de matrice des poids appliqués à un nœud, c'est-à-dire sous forme de valeurs multiplicatives appliquées aux entrées d'un neurone. Les réseaux de neurones sont devenus des méthodes d'apprentissage automatique très connues pour des applications de classifications, connaissances de forme, optimisations et prévisions. Le réseau de neurones est donc appelé : perceptron multi-couches (Multi layer perceptron - MLP).

Un modèle d'un neurone : L'unité de calcul de base du cerveau est le neurone. Chaque neurone reçoit des signaux d'entrée de ses dendrites et produit des signaux de sortie le long de son axone. L'axone se ramifie finalement et se connecte via des synapses aux dendrites des autres neurones (*Figure 20*).




Figure 20 : Un neurone dans le cerveau humain

Dans le neurone de computation (*Figure 21*), le neurone reçoit des signaux qui sont transmis par des dendrites (des entrées). Ce neurone intègre des signaux par une opération de multiplication des valeurs d'entrées X avec une matrice de poids W . Ensuite, une fonction d'activation f est appliquée sur la valeur d'intégration avant de l'envoyer au neurone suivant.

Les fonctions d'activation : ce sont des fonctions mathématiques appliquées sur des valeurs intégrées dans chaque neurone (*Figure 22*). Ils ont deux types de fonction : les fonctions de régression des valeurs **RELU**, les fonctions de catégories ***sigmoid***, ***tanh*** :




Figure 21: Un neurone artificiel

RELU :


$$f(x) = \max(0, x)$$

Sigmoïde :


$$f(x) = \frac{1}{1 + e^{-x}}$$

Tanh :


$$f(x) = \frac{e^x - e^{-x}}{e^x + e^{-x}}$$



RELU fonction



Sigmoïde fonction



Tanh fonction

Figure 22 : Graphiques des fonctions d'activation

Un réseau de neurone artificiel, c'est une organisation des couches hiérarchiques, où chaque neurone d'une couche est connecté à tous les neurones de la couche précédente ainsi qu'à ceux de la couche suivante. Cependant, les neurones qui appartiennent à la même couche ne sont pas connectés entre eux. Les valeurs sont transférées par une seule direction d'une couche à la couche qui la suit. Il y a trois types de couche : une couche d'entrée, une couche de sortie et des couches cachées. La couche d'entrée envoie des valeurs à tous les neurones de la couche suivante. Elle n'a donc pas de couche précédente. Les neurones de cette couche sont des

correspondants des variables du tableau de données. La couche de sortie reçoit des valeurs des neurones de la couche précédente. Cette couche est la dernière couche du modèle. Le nombre de leurs neurones est le nombre de classes fixées au préalable pour la classification. Les couches cachées et les matrices de poids représentent des connaissances qui sont extraites du modèle perceptron multicouches - MLP. Le processus d'entraînement passe par deux étapes : **feedforward** et **backpropagation**.

Le **feedforward** : *Figure 23*, un réseau MLP avec L couches, une couche d'entrée $C^{(1)}$ et une couche de sortie $C^{(L)}$. La couche cachée $l^{\text{ème}}$, $C^{(l)}$, a une matrice de 2-dimension $W^{(l)}$ avec $W_{ij}^{(l)}$ est le poids de transfert de la valeur du neurone $i^{\text{ème}}$ de la couche $(l - 1)$ au neurone $j^{\text{ème}}$ de la couche (l) .

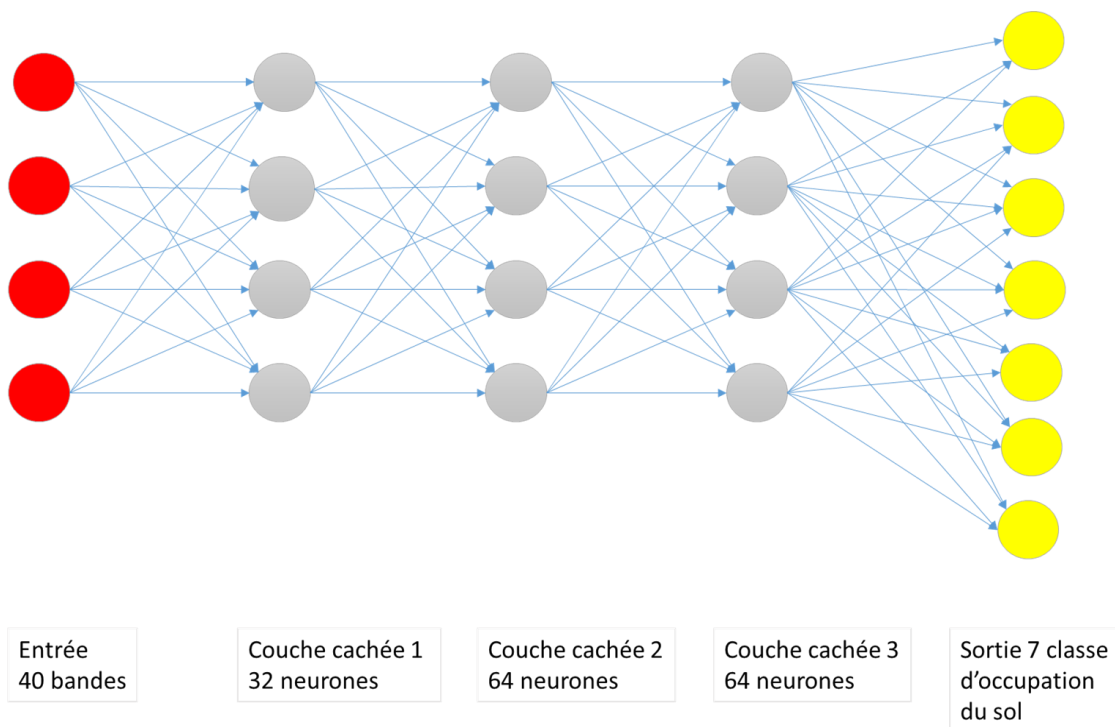


Figure 23 : Modèle d'un réseau de neurones

Les valeurs sont transférées de couche à couche (*Figure 24*). Si $X^{(l-1)}$ sont des sorties de couche $(l - 1)$, les sorties $X^{(l)}$ de couche (l) sont calculées par l'application d'une fonction d'activité f sur la somme des valeurs de sorties de la couche $(l - 1)$:

$$X^{(l)} = f^{(l)}(W^{(l)} X^{(l-1)} + b^{(l)})$$

Soit un tableau de données supervisées $n \times m : D = \{X|Y\}$, X est un ensemble des variables $X = \{X_1, X_2, \dots, X_n\}$ et $Y = \{y_1, y_2, \dots, y_m\}$ est un ensemble des valeurs supervisées. Les valeurs de prédiction \hat{Y} sont données par :

$$\hat{Y} = f^{(L)}(W^{(L)} X^{(L-1)} + b^{(L)})$$

Dans la dernière couche, il existe une fonction qui permet d'évaluer la qualité du modèle. La fonction est souvent appelée **loss-function** ou **cost-function**, et la valeur calculée par cette fonction est appelée "loss" ou "cost". L'objectif du **loss-function** est de minimiser l'erreur de prévision : *Mean Square Error*, *Cross Entropy Loss*.




Figure 24 : Illustration de l'étape Feedforward

Le Mean Square Error, MSE, est calculé par la moyenne des différences au carré des valeurs prévues et réelles. Sa valeur est importante quand le modèle présente plus d'erreurs. Son meilleur résultat est égal à zéro (0). Le *Mean Square Error (MSE)* est donné par :

$$Cost = \frac{1}{n} \sum_{i=1}^n \|y_i - \hat{y}_i\|^2$$

Le Cross Entropy Loss calcule un score qui résume la différence moyenne entre les distributions de probabilité réelles et prédites pour toutes les classes du problème. L'objectif est d'atteindre la valeur d'un score minimum. La valeur parfaite de **Cross Entropy Loss** est zéro (0). Le *Cross Entropy Loss* est donné par :

$$Cost = - \sum_{i=1}^n (y_i \log \log \hat{y}_i + (1 - y_i) \log \log (1 - \hat{y}_i))$$

Le Backpropagation : Figure 25, l'algorithme de **Backpropagation** a été proposé dans les années 1970s mais son importance n'a pas été appréciée avant les travaux de David Rumelhart, Geoffrey Hinton, et Ronald Williams (Rumelhart *et al.*, 1986). Leurs études ont décrit des réseaux de neurones où l'algorithme **Backpropagation** fonctionne plus rapidement que les approches d'apprentissage antérieures, ce qui permet d'utiliser des réseaux de neurones pour résoudre les problèmes insolubles. Aujourd'hui, l'algorithme **backpropagation** est le plus efficace

parmi les algorithmes d'apprentissage d'un réseau de neurones. Cet algorithme se base sur les optimisations des valeurs de **loss-function (Cost)** en utilisant des dérivées partielles $\frac{\partial Cost}{\partial w}$ de la fonction **Cost** par rapport à chaque poids w . Les méthodes d'optimisation sont principalement des **gradient descent, Stochastic gradient descent, mini-batch gradient descent**. Elles sont souvent utilisées dans les processus d'entraînement des réseaux de neurones.

Les dérivées partielles de **loss-function** par rapport aux valeurs de sorties de la couche (L) sont données par :

$$\delta_i^{(L)} = \frac{\partial cost}{\partial x_i^{(L)}} = \frac{\partial cost}{\partial \hat{y}_i}$$

$\nabla_x Cost$ est défini comme un vecteur composant des dérivées partielles $\delta_i^{(L)}$

$$\nabla_x Cost = \{\delta_i^{(L)}\}$$




Figure 25 : Illustration de l'étape backpropagation.

L'opération **Hadamard product** \odot : soient A et B qui sont deux matrices $M \times N$, l'opération **Hadamard product** entre A et B est définie par : $C = A \odot B$ avec $C_{i,j} = A_{i,j} B_{i,j}$, $(1 \leq i \leq N, 1 \leq j \leq M)$

Les erreurs de couche de sortie (L) sont calculées avec l'opération **Hadamard product** \odot données par :

$$\delta^{(L)} = \nabla_x Cost \odot f'(X^{(L)})$$

Pour la rétro-propagation, le sens part de la couche ($L-1$) vers la couche (1). Les erreurs de la couche (l) sont calculées par des erreurs de la couche suivante ($l+1$) par :

$$\delta^{(l)} = (W^{(l+1)} \delta^{(l+1)}) \odot f'(X^{(l)})$$

La mise à jour des poids w de chaque couche (l) dans l'itération t est donnée par :

$$W_t^{(l)} = W_{t-1}^{(l)} - \eta \cdot \delta_t^{(l)}$$

En résumé, l'algorithme **backpropagation** se présente comme suit :

1. Collecter des données observées. $\{X|Y\}$
2. La boucle : pour chaque itération t
 - 2.1. Propager des valeurs X de la couche (1) à la couche (L)
 - 2.2. Calculer Loss-Function :
 - 2.3. Rétro-propager des erreurs de la couche (L) à la couche (1) :
 - 2.4. Mettre à jour des matrices de poids par la méthode Gradient descent : Avec la vitesse de calcul
3. La condition d'arrêt de boucle

6.5.2 Convolutional neural network : CNN

Convolutional neural network (CNN) est un type particulier du réseau de neurones qui est entraîné plus facilement, et meilleur qu'un réseau de neurones avec des connectivités totales entre les couches adjacentes. Il gagne des succès pratiques dans la période de **deep learning**. **Le CNN** est largement adopté dans le domaine de traitement des images (LeCun *et al.*, 2015). Les CNNs sont conçus pour traiter des données qui se présentent sous la forme de tableaux multiples, par exemple des images colorées avec 03 bandes (RGV) ou les images multi spectrales. De nombreuses modalités de données se présentent sous la forme de tableaux multiples : 1D pour les signaux et les séquences, y compris le langage ; 2D pour les images ou les spectrogrammes audio ; et 3D pour les images vidéo ou volumétriques. Les CNNs reposent sur quatre idées clés : connexions locales, poids partagés, agrégation des caractéristiques et utilisation de nombreuses couches (LeCun *et al.*, 2015).

L'architecture du CNNs (*Figure 26*) s'organise en une série de couches : couche convolutive, couche de regroupement, couche perceptrons. Les unités dans une couche convolutive sont organisées dans les *feature-maps* dans lesquelles chaque unité est connectée aux patch locaux dans la couche précédente par les matrices de poids partagées qui sont appelées filter-bank. Le rôle de la couche de regroupement

(*pool-layer*) est la fusion des caractéristiques dans une fenêtre MxM en un pixel par des opérations maximales ou moyennes. Après une couche de regroupement, les *feature-maps* sont réduites. Ses bases caractéristiques sont conservées pour l'étape suivante.

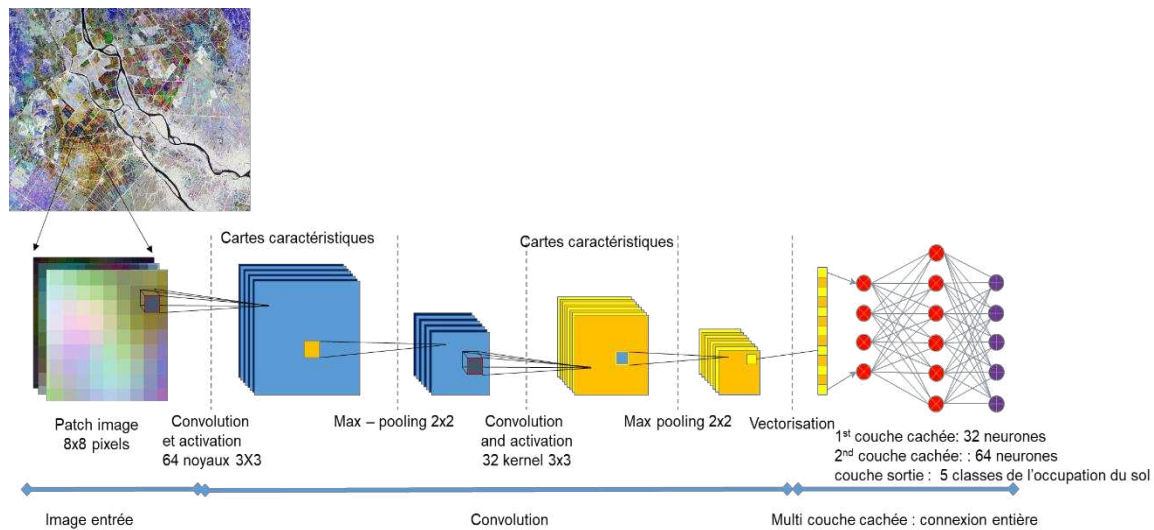


Figure 26 : Modèle CNN avec 02 couches convolutives, 02 couches de regroupement, une couche perceptron. Les images de l'entrée ont la taille 8x8, et la sortie a 05 classes de classification.

Dans une couche convolutive (Figure 27, Figure 28), les images ou les *feature-maps* sont convolutées avec un ensemble K noyaux $W = \{W_1, W_2, \dots, W_K\}$ et $\gamma = \{b_1, b_2, \dots, b_k\}$. La dimension de chaque noyau est k. Le *feature-map* de couche (l) est calculé par une opération convolutive \otimes avec le noyau k qui est donnée par :

$$X_k^{(l)} = f(W_k^{(l-1)} \otimes X^{(l-1)} + b_k^{(l-1)})$$

Dans la Figure 26, l'image d'origine est une image de Sentinel-2, la mission de classification est la détection des occupations du sol de la province Trande au delta du Mekong. Le modèle CNN est installé par plusieurs couches convolutives et couches de regroupement. Dans la première couche convolutive, il y a 64 noyaux de 3x3 dimensions. Six *feature-maps* sont sélectionnées avec des caractéristiques très particulières. Les caractéristiques sont utilisées pour classifier des classes : eau (a), bâtiment (c), des végétations (d), des non végétations (f), etc.

Une fonction de regroupement remplace la sortie de la couche à une position par une statistique récapitulative des pixels voisins. Par exemple, l'opération de *pooling-max* (Zhou et Chellappa, 1988) rapporte la sortie maximale dans un voisinage rectangulaire. D'autres fonctions de regroupement populaires incluent la moyenne d'un

quartier rectangulaire, la norme L^2 d'un quartier rectangulaire ou une moyenne pondérée basée sur la distance du pixel central.

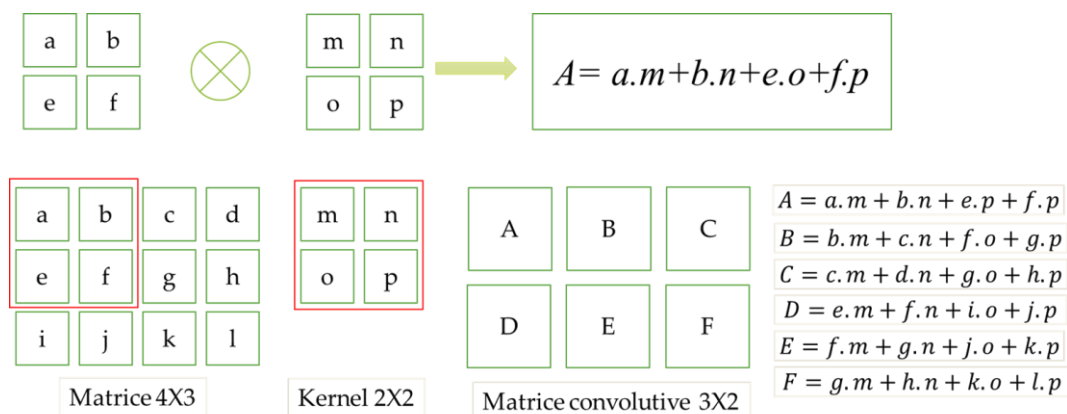


Figure 27 : Exemple de l'opération convolutive.

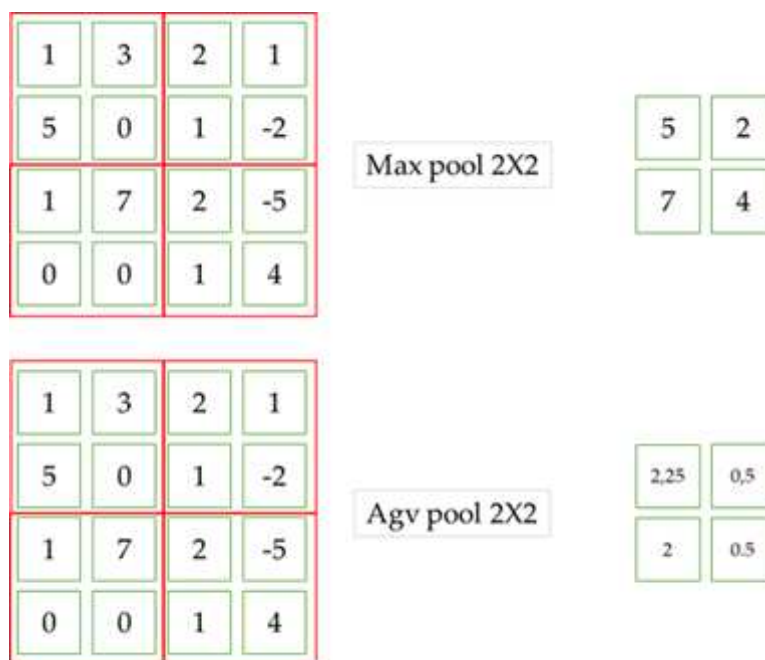


Figure 28 : Fonctions Max-Pool et Avg-Pool.

6.6. Evaluation de la précision des classifications

Quantifier l'étendue d'une classe d'occupation du sol avec son changement au fil du temps est une tâche non-triviale. Les superficies de l'occupation du sol sont déterminées à partir de données de télédétection. De telles cartes sont typiquement produites par une analyse de classification d'images. Les précisions des étendues de l'occupation du sol dépendent des résultats des méthodes de classification. Les récentes estimations des étendues de l'occupation du sol sont étudiées avec par exemple : l'étendue des zones urbaines (Potere et Schneider, 2007), les superficies des déforestations (Kuemmerle *et al.*, 2009; Olofsson *et al.*, 2011), et ont donné des

résultats avec des hauts taux d'erreurs. Comme illustré dans les dernières études (Kuemmerle *et al.*, 2009; Liu et Xia, 2010; Xian et Crane, 2005), même lorsque les classifications sont très précises, il est possible que la précision des cartes de l'occupation du sol soit faible et que la zone calculée à partir d'une carte de changement puisse être très biaisée.

A partir des travaux de (Olofsson *et al.*, 2014, 2013) l'objectif de ce chapitre est de présenter une méthode simple de l'utilisation des informations extraites d'un processus d'apprentissage automatique. Ceci dans une optique d'évaluation de la qualité de la carte de l'occupation du sol et d'estimation des superficies des classes ou du changement de l'occupation du sol pour construire des intervalles de confiance qui reflètent l'incertitude de cette estimation de superficies obtenues.

Des précisions calculées à partir des modèles d'apprentissage automatique sont évaluées en se basant sur des comparaisons spatiales explicites (par exemple : par pixel) entre la carte des classifications et la carte des références comme un échantillon d'unités. Les estimations des précisions qui sont présentées pour remédier aux inconvénients de l'évaluation des qualités de carte de l'occupation du sol sont listées ainsi :

- a) Estimation des précisions
- b) Estimation des superficies
- c) Estimation des erreurs types.

6.6.1 La matrice de confusion

La matrice de confusion, c'est la première méthode pour évaluer des différences entre des ensembles de catégories (*e.g.* des segmentations) ou pour calculer des précisions des classifications d'un modèle d'apprentissage automatique.

6.6.1.1 *La matrice de confusion origine*

Une matrice de confusion (*Tableau 7*) est construite sur la base des comparaisons entre les objets de deux ensembles qui sont classifiés en k classes. Chaque ligne correspond à une classe référence (classe réelle), chaque colonne correspond à une classe estimée (classe de prévision). Dans ce travail, les échantillons sont illustrés sous une forme d'images en 2D. Chaque valeur n_{ij} est le nombre d'éléments classe référence i correspondant à la classe estimée j . Des précisions sont calculées par des formules suivantes :

Les précisions de l'utilisateur- UA (User Accuracy).

$$U_i = \frac{n_{ii}}{n_i} \quad (15)$$

Les précisions du producteur- PA (Producer Accuracy).

$$P_i = \frac{n_{ii}}{n_i} \quad (16)$$

La précision globale – OAA (OverAll Accuracy)

$$O = \frac{\sum_{i=1}^k n_{ii}}{N} \quad (17)$$

Tableau 7 : Matrice de confusion de k classes.

Classes	1	2	3	...	k	total
1	n_{11}	n_{12}	n_{13}	...	n_{1k}	$n_{1.}$
2	n_{21}	n_{22}	n_{23}	...	n_{2k}	$n_{2.}$
⋮	⋮	⋮	⋮	⋮	n_{1k}	$n_{1.}$
k	n_{k1}	n_{k2}	n_{k3}	...	n_{kk}	$n_{k.}$
Total	$n_{.1}$	$n_{.2}$	$n_{.3}$...	$n_{.k}$	N

A l'aide des cartes, des superficies de classe i sont représentées par S_i et la superficie totale $S_{tot} = \sum S_i$. Pour servir les formules dans les étapes suivantes, un vecteur des poids ($W_i = \frac{S_i}{S_{tot}}$) est ajouté à la matrice de confusion (Tableau 7).

6.6.1.2 La matrice de confusion estimée

Le Tableau 8 présente des informations sur l'échantillon en calculant le nombre d'objets pour chaque classe. Pour avoir des estimations de précisions, la proportion de la superficie de cellule i, j dans la matrice de confusion est calculée par :

$$p_{ij} = W_i \frac{n_{ij}}{n_i} \quad (18)$$

Tableau 8 : Etendue de la matrice de confusion

Classes	1	2	3	...	k	total	Superficies (S)	Poids (W)
1	n_{11}	n_{12}	n_{13}	...	n_{1k}	$n_{1.}$	S_1	W_1
2	n_{21}	n_{22}	n_{23}	...	n_{2k}	$n_{2.}$	S_1	W_2
⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮
k	n_{k1}	n_{k2}	n_{k3}	...	n_{kk}	$n_{k.}$	S_k	W_k
Total	$n_{.1}$	$n_{.2}$	$n_{.3}$...	$n_{.k}$	N	S_{tot}	

Le *Tableau 9* est construit avec des proportions p_{ij} . Les précisions et ses estimations sont calculées directement par ce tableau.

Tableau 9 : Matrice de confusion estimée.

1	p_{11}	p_{12}	p_{13}	...	p_{1k}	$p_{1.}$
2	p_{21}	p_{22}	p_{23}	...	p_{2k}	$p_{2.}$
⋮	⋮	⋮	⋮	⋮	⋮	⋮
k	p_{k1}	p_{k2}	p_{k3}	...	p_{kk}	$p_{k.}$
Total	$p_{.1}$	$p_{.2}$	$p_{.3}$...	$p_{.k}$	1

6.6.2 L'estimation des précisions

En remplaçant p_{ij} de équation (18) aux équations (19)(20)(21) les estimations des précisions sont représentées par les formules suivantes qui ont été démontrées par les études de (Strahler *et al.*, 2006) :

Estimation des précisions de l'utilisateur (User Accuracy) :

$$\hat{U}_i = \frac{p_{ii}}{p_{i.}} \quad (19)$$

Estimation des précisions du producteur (Producer Accuracy) :

$$\hat{P}_i = \frac{p_{ii}}{p_{.i}} \quad (20)$$

Estimation de la précision globale (OverAll Accuracy) :

$$\hat{O} = \sum_{i=1}^k p_{ii} \quad (21)$$

Les estimateurs de la variance sont fournis ci-dessous et la racine carrée de la variance estimée donne l'erreur type de l'estimateur (Olofsson *et al.*, 2014).

Estimation des variances pour les précisions de l'utilisateur \hat{U} :

$$\hat{V}(\hat{U}_i) = \frac{\hat{U}_i(1 - \hat{U}_i)}{(n_{i.} - 1)} \quad (22)$$

Estimation des variances pour les précisions du producteur \hat{P} :

$$\hat{V}(\hat{P}_j) = \frac{1}{\hat{N}_j^2} \left[\frac{n_j(1 - \hat{P}_j)\hat{U}_j(1 - \hat{U}_j)}{(n_j - 1)} + \hat{P}_j \sum_{i \neq j}^k \frac{n_i^2 \frac{n_{ij}}{n_i} \left(1 - \frac{n_{ij}}{n_i}\right)}{n_i - 1} \right] \quad (23)$$

Avec $\hat{N}_j = \sum_{i=1}^k \frac{n_i}{n_i} n_{ij}$

Estimation des variances pour la précision globale \hat{O} :

$$\hat{V}(\hat{O}) = \sum_{i=1}^k \frac{W_i^2 \hat{U}_i(1 - \hat{U}_i)}{(n_i - 1)} \quad (24)$$

6.6.3 L'estimation des superficies.

Les valeurs de l'estimation des superficies de classes sont calculées par la formule suivante (Olofsson *et al.*, 2013) :

$$\hat{S}_i = S_{tot} \times p_i \quad (25)$$

L'erreur type de l'estimation des superficies de classe i :

$$\hat{V}(\hat{S}_j) = S_{tot} \times \hat{S}(p_j) \quad (26)$$

Avec $\hat{S}(p_j)$ qui sont des erreurs types de chaque classe j estimée doivent être calculées par la formule de (Cochran, 1977) :

$$\hat{S}(p_j) = \sqrt{\sum_{i=1}^k W_i^2 = \frac{p_{ij}(1 - p_{ij})}{(n_j - 1)}} \quad (27)$$

6.6.4 Les exemples

6.6.4.1 Evaluation des précisions d'une carte d'occupation

Dans cet exemple, une carte d'occupation du sol (*Figure 29*) est générée par une application de la méthode **CNN – Convolutional Neuron Network** pour détecter cinq classes d'occupation du sol qui sont : l'eau permanente, les rizières, les bâtiments, les vergers, les forêts. Des données de validation ont été générées sous forme de polygones, ou région d'intérêt (ROI), depuis une carte de référence. Le processus de l'estimation des précisions commence en construisant le tableau de confusion étendue (*Tableau 10*):

Tableau 10 : Matrice de confusion de la carte d'occupation du sol au delta du Mékong en 2019.

Classes	1	2	3	4	5	Pixels	Superficie (km2)	Poids (Wi)
Eau	89301	0	0	0	112	89413	270.87	0.0234
Rizières	174	83256	40	0	2121	85591	6,181.17	0.5346
Bâtiment	127	1001	22341	712	906	25087	718.69	0.0622
Jardin	0	1274	58	140622	3737	145691	1,680.25	0.1453
Forêt	423	1121	82	698	252028	254352	2,710.49	0.2344
Total	90025	86652	22521	142032	258904	600134	11,561.46	1.0000

Des précisions sont calculées à l'aide de la matrice de confusion, pour évaluer la qualité de la méthode CNN à l'aide du logiciel E-cognition 10.0. Dans le *Tableau 11*, les valeurs de la précision reflètent une bonne qualité de classification, cependant, les incertitudes ne sont pas calculées.

Tableau 11 : Précisions des classifications de l'occupation du sol au delta du Mékong en 2019.

Nom de Classe	Code de classe	Précision de l'utilisateur	Précision du producteur
Eau permanente	1	99.9%	99.2%
Rizières	2	97.3%	96.1%
Bâtiment	3	89.1%	99.2%
Jardin	4	96.5%	99.0%
Forêt	5	92.98%	97.3%
Précision globale		97.9%	




Figure 29 : Carte de l'occupation du sol de province An Giang et province Dong Thap au delta du Mékong en 2019.

Ainsi à l'étape suivante, on calcule la matrice de confusion par les formules (18), (27) (*Tableau 12*)

Tableau 12 : Matrice de confusion estimée

Classes	1	2	3	4	5	p_i
Eau	0.023399	-	-	-	0.000029	0.023429
Rizières	0.001087	0.520050	0.000250	-	0.013249	0.534635
Bâtiment	0.000315	0.002480	0.055358	0.001764	0.002245	0.062162
Jardin	-	0.001271	0.000058	0.140275	0.003728	0.145332
Forêt	0.000390	0.001033	0.000076	0.000643	0.232300	0.234442
p_i	0.025191	0.524835	0.055741	0.142683	0.251551	
$\hat{S}(p_j)$	0.000089	0.000311	0.000129	0.000099	0.000303	

Dans la dernière étape, des précisions estimées sont calculées par des formules (19)(20)(21)(22)(23)(24)(26). Ainsi, on obtient le tableau d'évaluation des précisions de la carte de l'occupation du sol dans la zone d'étude (deux provinces AnGiang et DongThap au delta du Mékong) *Tableau 13*.

D'après la deuxième ligne, dans le *Tableau 13*:

- La superficie observée est égale à **6,181.169** km², la superficie estimée avec son erreur type est égale à **6,067.856 ± 7.191**.
- La classe Rizières a une précision de l'utilisateur de 96.1% et une précision du producteur de 97.3%. Le processus d'estimation donne une précision estimée de l'utilisateur de 97.27 ± 0.11 % et une précision estimée du producteur de 99.09 ± 0.03 %.
- Les valeurs de précision estimées sont supérieures à celles des valeurs d'origine (du *Tableau 11*) (99.09% > 97.3% ou 97.27% > 96.1%) car la superficie des rizières est la plus importante (53% au total).

6.6.4.2 *Evaluation des précisions des changements de l'occupation du sol*

Dans un deuxième exemple, on a généré deux cartes d'occupation du sol en 2019 et 2020 (*Figure 30*). A l'aide de méthodes d'estimations des précisions (Olofsson *et al.*, 2014, 2013) des superficies des changements entre 2019 et 2020 sont données par des valeurs estimées.

Tableau 13 : Estimations des précisions de la carte de l'occupation du sol.

Classes	Précision estimée du producteur %	Précision estimée de l'utilisateur %	Superficies observées (km ²)	Superficies estimées (km ²)
Eau permanente	92.89 ± 0.64	99.87 ± 0.02	270.868	291.241 ± 2.058
Rizières	99.09 ± 0.03	97.27 ± 0.11	6,181.169	6,067.856 ± 7.191
Bâtiment	99.31 ± 0.14	89.05 ± 0.39	718.686	644.451 ± 2.988
Jardin	98.31 ± 0.09	96.52 ± 0.09	1,680.249	1,649.624 ± 2.278
Forêt	92.35 ± 0.22	99.09 ± 0.04	2,710.493	2,908.293 ± 7.000
Précision globale estimée %		97.14 ± 0.007		

Des comparaisons pixel par pixel entre les deux cartes sont présentées dans le *Tableau 14*. Des valeurs de $(n_{11}, n_{22}, n_{33}, n_{44}, n_{55})$ sont des superficies sans changement. Celle n_{ij} représente le nombre des pixels qui change de *classe i* en 2019 à *classe j* en 2020. Ici dans cet exemple, des superficies qui changent sont évaluées par les valeurs estimées dans le *Tableau 15* qui donne les proportions du changements de chaque classe.




Figure 30 : L'occupation du sol en 2019 à gauche et en 2020 à droite.

Tableau 14 : Matrice de changements de l'occupation du sol de 2019 à 2020.

Classe	1	2	3	4	5	Total
Eau	2,342,94	58,385	16,502	3,894	181,879	2,603,604
Rizières	326,378	47,785,422	146,477	850,077	10,305,497	59,413,851
Bâtiment	50,686	1,692,786	3,113,389	987,977	1,063,224	6,908,062
Jardin	10,221	2,268,692	575,195	8,965,911	4,330,660	16,150,679
Forêt	459,016	8,801,034	409,884	1,914,567	14,468,954	26,053,455
Total	3,189,24	60,606,319	4,261,447	12,722,426	30,350,214	111,129,651

Dans le *Tableau 15*, la précision globale $OAA = 69 \pm 0.01$ signifie que le pourcentage des superficies qui ne changent pas est de l'ordre de 69% avec une variance égale à 0.01 %. A la ligne 3, la précision de l'utilisateur de la classe bâtiments, $UA = 45.07 \pm 0.04$ % montre la proportion des changements ($1 - UA$) qui est égale à 55 %. La classe bâtiments est la classe qui a connu plus de changements par rapport aux autres classes.

Tableau 15 : Précisions estimées de la classification par CNN.

Classe	PA (%)	UA(%)	Superficies (km2)
Eau permanente	73.46 ± 0.04	89.99 ± 0.04	331.795 ± 0.215
Rizières	78.85 ± 0.01	80.43 ± 0.01	$6,305.228 \pm 0.894$
Bâtiment	73.06 ± 0.04	45.07 ± 0.04	443.343 ± 0.350
Jardin	70.47 ± 0.02	55.51 ± 0.02	$1,323.588 \pm 0.567$
Forêt	47.67 ± 0.01	55.54 ± 0.02	$3,157,509 \pm 0.911$
OAA (%)	69 ± 0.01		

Chapitre 7. L'Analyse orientée objet d'images satellite

7.1. Émergence de l'approche « orientée objet »

La plupart des méthodes de traitement d'images développées depuis le début des années 1970 sont basées sur la classification de pixels individuels en utilisant le concept d'un espace de caractéristiques multidimensionnelles. Dans (Weng, 2009), une série de techniques de classification a été présentée et développée pour classer les images à basse résolution par pixels. Cependant, la demande actuelle de la communauté de la télédétection et de ses services concerne des résultats de classification toujours plus rapides et plus précis. Cet objectif n'est pas entièrement satisfait en raison des différentes caractéristiques de l'imagerie à haute résolution et des besoins variés des utilisateurs (Wang *et al.*, 2009). Les nouveaux capteurs à haute résolution augmentent considérablement la variabilité spectrale au sein d'une même classe et, par conséquent, diminuent la précision potentielle d'une approche de la classification purement basée sur les pixels. Hay *et al.* (1996) appellent cela « le problème de la haute résolution » (Figure 31).




Figure 31 : Relation entre les objets et la résolution spatiale. (a) basse résolution : pixels nettement plus grands que les objets (b) résolution moyenne : les tailles des pixels et des objets sont du même ordre, les techniques pixel par pixel sont appropriées.

7.2. Définition du concept de GEOBIA

Dans leur travaux Hay et Castilla (2008) ont défini le concept comme suit : « L'analyse d'images basée sur les objets géographiques (GEOBIA) est une sous-discipline de la science de l'information géographique (GEOScience) consacrée au développement de méthodes automatisées pour partitionner l'imagerie de télédétection en objets d'image significatifs, et évaluer leurs caractéristiques à travers les échelles spatiales, spectrales et temporelles, afin de générer de nouvelles informations géographiques dans un format prêt pour le SIG. »

7.3. Evaluation de GEOBIA

Les évaluations de GEOBIA sont données par Hay et Castilla (2008), elles sont poursuivies ensuite (Blaschke, 2010; Hay *et al.*, 1996). Grâce à ces travaux, on connaît les avantages et les inconvénients de GEOBIA.

7.3.1 Avantages de GEOBIA

Les objets-images présentent des caractéristiques utiles (par exemple, la forme, la texture, les relations contextuelles avec d'autres objets) qui font défaut aux pixels individuels. Les objets-images peuvent être plus facilement intégrés dans un SIG vectoriel que les cartes matricielles classées par pixel.

L'utilisation d'objets-images comme unités de base réduit la charge des classificateurs par ordre de grandeur, tout en permettant à l'utilisateur de tirer parti de techniques plus complexes. Les objets-images sont moins sensibles au problème des unités de surface modifiables que les unités qui ne correspondent pas à la structure du phénomène étudié.

7.3.2 Inconvénient de GEOBIA

Certains des algorithmes d'extraction des objets offrent des options trop compliquées, ce qui oblige l'analyste à prendre le temps de les régler.

Le traitement de très grands échantillons de données présente de nombreux défis. Même si GEOBIA est plus efficace que les approches basées sur les pixels, la segmentation d'une image multi-spectrale de centaines ou de milliers de méga-pixels est une tâche énorme, d'où la nécessité de solutions efficaces de multi-traitement (des solutions de traitement en parallèle).

La segmentation ne donne pas de solution unique, par exemple, (i) changer la profondeur de bit de la mesure d'hétérogénéité peut conduire à des segmentations différentes. (ii) Même des photo-interprètes humains ne délimitent pas exactement les mêmes choses.

7.4. Paradigme de GEOBIA

Les facteurs d'un paradigme de GEOBIA sont : des données, des méthodes de segmentations, des méthodes de classifications (Baatz *et al.*, 2008; Blaschke *et al.*, 2014; Castilla et Hay, 2008).

7.4.1 Etape de travail dans le cadre de GEOBIA

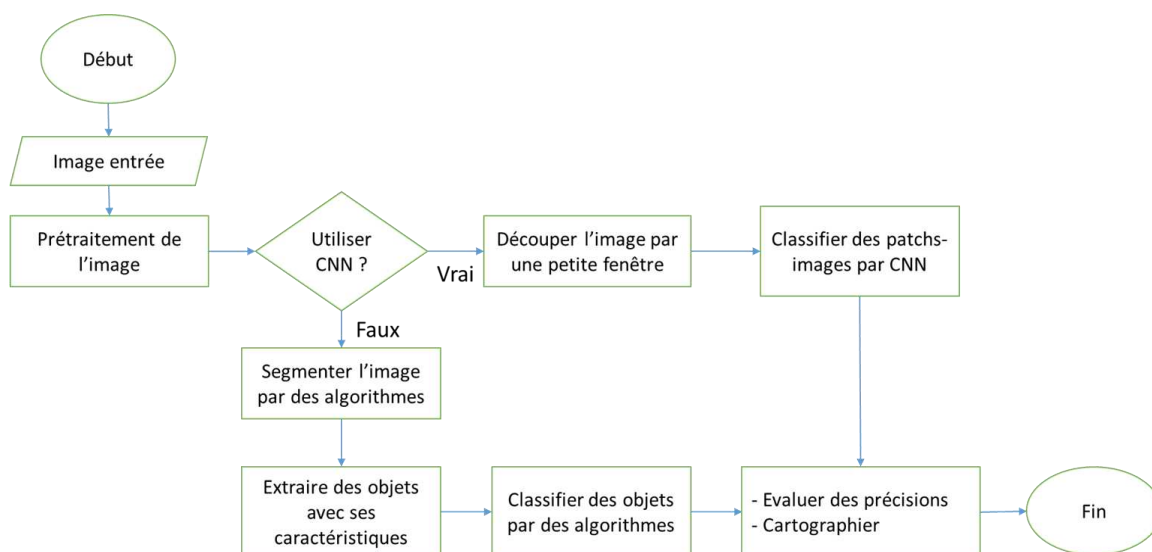


Figure 32 : Processus de GEOBIA

Les données utilisées dans GEOBIA comprennent des images satellites qui sont des données entrées. Et elles sont enregistrées sous forme de fichiers RASTER. Les pixels dans une image sont organisés en 2-dimensions. Chaque pixel est un vecteur K -valeurs où K est le nombre de bande dans l'image optique. Dans le cas des images SAR il y a un nombre doubles de polarisations. Et dans la troisième figure de cas, ce sont les images fusionnées où K est le total des bandes. La structure des données satellites est présentée dans les sections Chapitre 5, Chapitre 6.

Les objets sont des résultats de l'étape de segmentation (Figure 32) et sont sauvegardés dans un fichier GIS sous forme des polygones et ses coordonnées. On a besoin d'une sous-étape pour extraire les caractéristiques (les moyennes, les écarts-types, la superficie, ...). Les échantillons entraînés et les échantillons validés sont collectés à partir des objets extraits dans l'étape de segmentation avec des informations d'observation.

7.4.2 Méthodes de machine learning

7.4.2.1 Méthodes non-supervisées

Dans GEOBIA, la segmentation est la partition d'un ensemble de mesures sur la base de l'homogénéité. Elle divise une image ou toute donnée matricielle ou ponctuelle en régions spatialement continues, disjointes et homogènes appelées « Objets » (Blaschke *et al.*, 2014). Les objets sont des facteurs principaux dans le processus de GEOBIA. Ils sont extraits physiquement par des découpages avec une

fenêtre $m \times m$ ou des algorithmes d'apprentissage automatique non-supervisés. Dans cette thèse, les méthodes de segmentations sont présentées dans la section 6.3. Les algorithmes de segmentation donnent plusieurs paramètres. Et les optimisations des paramètres améliorent l'homogénéité intra-segment, l'hétérogénéité inter-segment et la précision de la classification (Gao *et al.*, 2011; Yang *et al.*, 2015)

7.4.2.2 Méthodes supervisées

Les algorithmes d'apprentissage automatique supervisés ont été utilisés comme les méthodes de classification automatique. Il y a des méthodes de classification appliquées sur des travaux de télédétection, par exemple Support vector machine, *Random Forest*, Multi-Layer Perceptron (Yang *et al.*, 2015)

7.4.3 Méthodes de deep learning

Depuis 2006, les algorithmes utilisant l'apprentissage profond (Deep Learning) sont populaires pour l'analyse des images de télédétection (Hinton *et al.*, 2006; Zhu *et al.*, 2017). Il y a des architectures puissantes de modèles Deep Learning qui ont été développées pour la classification des images de télédétection (Boualleg *et al.*, 2019) par exemple celui de CNN (Figure 33). Les comparaisons des performances entre des algorithmes d'apprentissage automatique et des algorithmes Deep Learning sont présentées dans les études de (Fu *et al.*, 2018; Jozdani *et al.*, 2019). Selon ces travaux, on a discuté des performances des algorithmes *Deep Learning* par rapport aux algorithmes d'apprentissage automatique classiques pour la classification des images satellites.

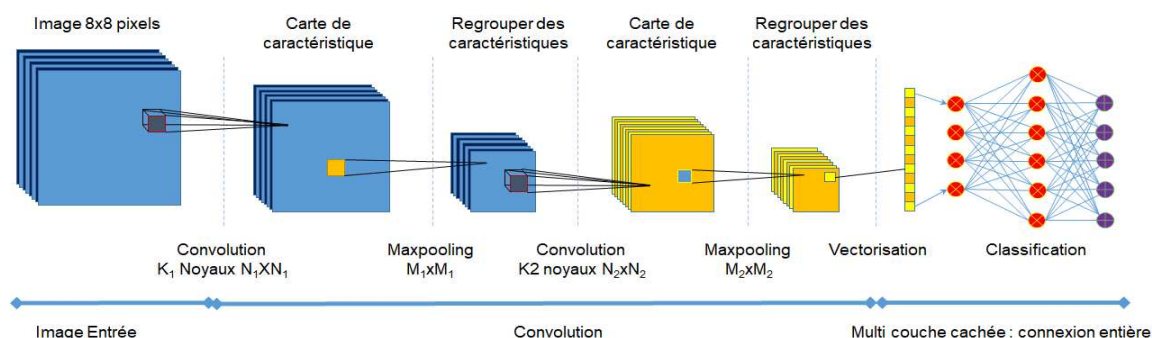


Figure 33 : Modèle Générale de CNN.

Partie 3 : De l'acquisition des données aux Applications

Chapitre 8. Détection des changements de l'occupation du sol dans le delta du fleuve Rouge (Viêt-Nam)

L'étude de l'utilisation et la couverture du sol est essentielle dans la planification spatiale et l'élaboration des plans de gestion, notamment pour la conservation de l'éco-environnement et la planification urbaine dans les zones côtières. Récemment, en plus de la disponibilité de l'imagerie satellitaire européenne à très haute résolution (VHR) comme Sentinel-2, l'utilisation des nouvelles méthodes comme celles basées sur les objets d'image est combinée avec l'imagerie VHR pour produire de meilleurs résultats.

Dans un but de cartographier les changements d'utilisation des terres dans le delta du fleuve Rouge au Viêt-Nam, cette première application met en œuvre un traitement d'images via une analyse basée sur les objets (GEOBIA). Il s'agit à la fois d'une opportunité et d'un défi pour GEOBIA dans la cartographie et la surveillance de l'utilisation des terres.

Avec l'avènement des données multi-capteurs et à plus haute résolution spatiale, la recherche s'est concentrée sur la texture de l'image ainsi que sur les informations contextuelles qui décrivent l'association des valeurs des pixels voisins et qui se sont avérées capables d'améliorer les résultats de la classification des images (Hay, 1994; Hay *et al.*, 1997; Marceau *et al.*, 1990).

La nouveauté de cette application est d'ordre méthodologique. La méthodologie propose un processus en deux étapes de segmentation puis de classification des segments créés. Le processus de segmentation initial influence fortement la précision de la classification. Il est généralement très difficile d'obtenir des résultats de segmentation satisfaisants en utilisant les mêmes paramètres pour tous les objets des images.

8.1. Zone d'étude

De par sa position géographique, le delta du fleuve Rouge (*Figure 34*) regroupe la majorité de la population et de l'activité économique de la moitié nord du Viêt-Nam où environ la moitié de la production de riz du pays s'y déroule. En revanche, l'exploitation intensive des ressources par une population surabondante (densité de population de 962 habitants/km²) pose d'importants problèmes. Par ailleurs, des inondations périodiques menacent les activités agricoles dont le rendement s'accélère, ce qui fragilise l'environnement (voir titre 3.1).

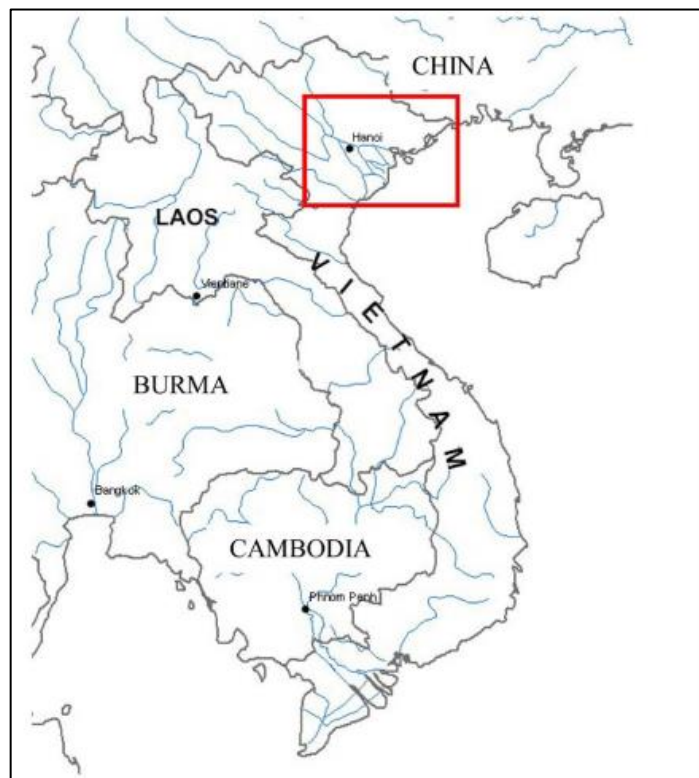


Figure 34 : Delta du fleuve Rouge au Viêt-Nam.

La récente transition du pays vers une économie de marché a entraîné une augmentation des rendements à la suite d'activités agricoles intensifiées qui ont conduit à une plus grande vulnérabilité environnementale.

Dans les zones résidentielles, situées sur des terrains plus élevés et hors de portée des inondations, l'occupation des terres est caractérisée par la présence des villages où l'on trouve des vergers saisonniers et des arbres d'ombrage comme le bananier, l'eucalyptus et le filao, ainsi que quelques arbres fruitiers. Dans certaines zones de haute altitude, le filao est cultivé pour la production de bois et pour la protection des villages de l'intérieur contre les tempêtes. Dans la région côtière, l'occupation des terres est principalement de type agricole, avec le riz comme principale culture. Dans certaines zones très basses, salées et récemment défrichées, le scirpe est temporairement cultivé pour améliorer la qualité du sol avant de laisser place aux cultures de riz. Au contraire, dans les zones côtières salines et les estuaires, la végétation se développe naturellement pour former des forêts. Cependant, la formation végétale prédominante est la forêt de palétuviers, principalement du type *Sonneratia*, avec une hauteur allant de 1 à 3,5 m. Une partie importante de cette zone est actuellement couverte par des étangs d'aquaculture pour la culture de crevettes et de crabes, utilisant des méthodes industrielles aussi bien que traditionnelles (Niculescu et Lam, 2019).

8.2. Données mises en œuvre

Pour cette application, nous avons utilisé les données du satellite optique Sentinel-2 et les données optiques de Landsat-8 (*Tableau 16*). La principale source de données provient des satellites Sentinel-1. Toutes les images Sentinel-2 (niveau 1C) couvrant l'ensemble de la zone d'étude ont été téléchargées depuis le Sentinel Scientific Hub de l'ESA (ESA, 2018). Ce satellite est capable de fournir des images avec une largeur au sol de 290 km, et une périodicité de 5 jours. Les acquisitions sont réalisées selon trois résolutions en fonction de la bande spectrale : 10, 20 et 60 m (*Tableau 17*).

Par ailleurs des images Landsat ont été téléchargées depuis le site officiel Landsat <https://earthexplorer.usgs.gov/>. Le satellite Landsat-8 transporte une charge utile à deux capteurs, l'imageur terrestre opérationnel (OLI) et le capteur infrarouge thermique (TIRS). L'OLI dispose de deux bandes supplémentaires de longueurs d'onde réfléchissantes : une nouvelle bande bleue à courte longueur d'onde (0,43 - 0,45 μm) destinée à améliorer la sensibilité à la chlorophylle et aux autres matières en suspension dans les eaux côtières et à récupérer les propriétés des aérosols atmosphériques, et une nouvelle bande infrarouge à ondes courtes (1,36 - 1,39 μm) pour la détection des cirrus. Les autres bandes OLI sont spectralement plus étroites dans la plupart des cas que les bandes ETM+ correspondantes (Roy *et al.*, 2014) (*Tableau 18*).

Les dates de prise de vue des images satellites disponibles pour la zone d'étude, ont été choisies en fonction des principales étapes de la culture du riz dans le delta du fleuve Rouge.

D'une manière générale, il y a deux saisons de récolte par an dans le delta du fleuve Rouge : la saison printemps-été (de février à juillet) et la saison automne-hiver (d'août à janvier). La première étape concerne les préparatifs dans les rizières : à partir de la mi-janvier, la récolte ayant lieu 100 jours plus tard, fin avril/mai. La deuxième étape à partir de la fin du mois de mai, concerne les préparations du sol après la première récolte, cette étape se produit jusqu'à la fin du mois d'août/début du mois de septembre. Par ailleurs, de septembre à la mi-janvier, on cultive des légumes (*Tableau 19 et 20*)

Tableau 16 : Ensemble de données satellitaires disponibles.

Number	Date	Satellite
1	05/26/2018	Sentinel-2
2	06/20/2018	Sentinel-2
3	07/05/2018	Sentinel-2
4	11/02/2018	Sentinel-2
5	12/17/2017	Sentinel-2
6	09/17/2017	Landsat-8
7	07/30/2017	Sentinel-2
8	04/21/2017	Sentinel-2
9	06/15/2016	Sentinel-2
10	04/23/2016	Landsat-8
11	06/15/2016	Sentinel-2
12	04/23/2016	Landsat-8

Tableau 17 : Résolutions spatiales et spectrales du satellite Sentinel-2.

Sentinel-2 Bands	longueur d'onde (μm)	Résolution (m)	Bande passante (nm)
Band 1-Coastal aerosol	0.443	60	20
Band 2-Blue	0.49	10	65
Band 3-Green	0.56	10	35
Band 4-Red	0.665	10	30
Band 5-Vegetation Red Edge	0.705	20	15
Band 6-Vegetation Red Edge	0.74	20	15
Band 7-Vegetation Red Edge	0.783	20	20
Band 8-Near Infrared (NIR)	0.842	10	115
Band 8A-Narrow NIR	0.865	20	20
Band 9-Water vapor	0.945	60	20
Band 10-SWIR—Cirrus	1.375	60	20
Band 11-SWIR 1	1.61	20	90
Band 12-SWIR 2	2.19	20	180

Tableau 18 : Résolutions spatiales et spectrales du satellite Landsat-8.

	(micromètres)	(mètres)
Band 1-Coastal aerosol	0.43 - 0.45	30
Band 2-Blue	0.45 - 0.51	30
Band 3-Green	0.53 - 0.59	30
Band 4-Red	0.64 - 0.67	30
Band 5-Near infrared (NIR)	0.85 - 0.88	30
Band 6-SWIR 1	1.57 - 1.65	30
Band 7-SWIR 2	2.11 - 2.29	30
Band 8-Panachromatique	0.50 - 0.68	15
Band 9-Cirrus	1.36 - 1.38	30
Band 10-Thermal infrared (TIRS) 1	10.60 - 11.19	100
Band 11-Thermal infrared (TIRS) 2	11.50 - 12.51	100

8.3. Méthodologie

La méthodologie porte sur le traitement et l'analyse des images des satellites Sentinel-2 et Landsat-8 (*Figure 35*) via l'application de l'analyse d'image GEOBIA en combinaison avec l'empilement des séries temporelles.

GEOBIA est un paradigme évolutif avec des outils, des logiciels, des méthodes, des règles et un langage spécifique et il est de plus en plus utilisé pour les études qui ont besoin de conceptualiser et de formaliser les connaissances représentant la réalité basée sur l'emplacement (Blaschke *et al.*, 2014). Le processus de classification de cette méthode utilise un processus de segmentation hiérarchique au stade du prétraitement afin que les caractéristiques de l'objet puissent être complétées par des informations supplémentaires telles que la texture, le contexte et d'autres informations liées à l'objet.

8.3.1 Calcul du NDVI

La première étape du traitement des images, Sentinel-2 et Landsat-8, est le calcul du NDVI (Normalized Difference Vegetation Index) (Rouse *et al.*, 1973), qui est un indicateur permettant de décrire la verdure, la densité et l'état de la végétation.

Les indices de végétation ont été calculés pour l'image de réflectance Sentinel-2A, il est défini par la réflectance de la bande rouge (RED) et de la bande proche infrarouge (NIR) car elles détectent des profondeurs très différentes à travers les couverts végétaux. La bande Rouge se situe dans la région de forte absorption de la chlorophylle, tandis que la bande NIR présente une réflectance élevée du couvert végétal dans cette zone.

8.3.1.1 *Indice de végétation pour Sentinel-2*

$$\text{NDVI} = \frac{\text{NIR} - \text{RED}}{\text{NIR} + \text{RED}} = \frac{\text{B8} - \text{B4}}{\text{B8} + \text{B4}}$$

Tableau 19 : Calendrier du riz dans la zone de la côte de la delta du fleuve Rouge

Saison de culture	Période	culture	croissance	récolte
	Récolte Précoce	12/25-12/30	02/05-02/10	05/20-05/25
Printemps- été	Récolte annuelle	01/05-01/20	02/20-02/25	06/01-06/15
	Récolte tardive	02/25-03/05	01/25-02/05	06/25-06/30
	Récolte Précoce	05/20-05/30	06/01-06/10	09/01-09/10
Automne - hiver	Récolte annuelle	06/01-06/10	06/10-06/20	10/25-11/10
	Récolte tardive	06/25-07/05	06/25-07/05	11/05-11/25

8.3.1.2 *Indice de végétation pour Landsat-8*

$$\text{NDVI} = \frac{\text{NIR} - \text{RED}}{\text{NIR} + \text{RED}} = \frac{\text{B5} - \text{B4}}{\text{B5} + \text{B4}}$$

Une fusion ou empilement des couches a été effectué en ajoutant toutes les couches d'images optiques traitées, et ce après une normalisation des couches à la même plage de valeurs. Les couches d'images suivantes ont été empilées :

- Images 2016 : Bandes de réflectance Sentinel-2A (4 × 2 = 8 bandes) ; NDVI Sentinel-2A (2 bandes) ; avec un total 2016 = 10 bandes ;
- Images 2017 : Sentinel-2A (4 × 3 = 12 bandes) ; bandes de réflectance Landsat-8 (4 bandes) ; NDVI Sentinel-2A (3 bandes) ; NDVI Landsat-8 (1 bande) ; Total 2017 = 20 bandes.
- Images de 2018 : Bandes de réflectance Sentinel-2A (4 × 4 = 16 bandes) ; NDVI Sentinel-2A (1 × 4 = 4 bandes) ; Total 2018 = 20 bandes.

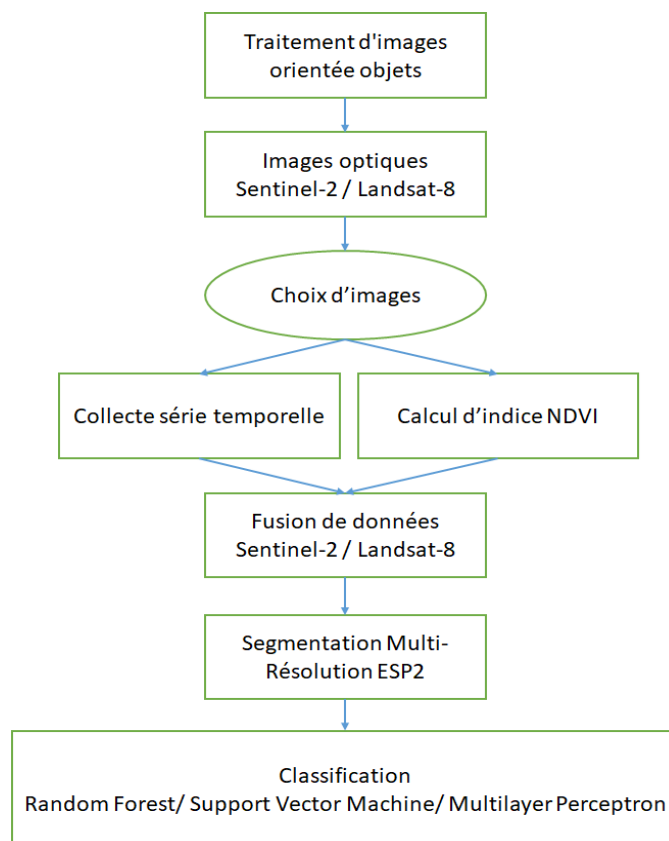


Figure 35 : Chaîne de prétraitement et de traitement.

Tableau 20 : Calendrier des cultures de riz et passages des Satellites (bleu Landsat, jaune Sentinel -2).

	2016												2017												2018														
	1	2	3	4	5	6	7	8	9	10	11	12	1	2	3	4	5	6	7	8	9	10	11	12	1	2	3	4	5	6	7	8	9	10	11	12			
Printemps- Eté	précoce		annuelle		tardive								précoce		annuelle		tardive								précoce		annuelle		tardive										
					précoce		annuelle		tardive						précoce		annuelle		tardive								précoce		annuelle		tardive								
Automne - Hiver																																							

8.3.2 Segmentation des images

Une multi segmentation des images à l'aide du nouvel outil Estimation du Paramètre d'Échelle (ESP2) a été effectuée, c'est une étape fondamentale dans GEOBIA, mais il n'existe actuellement aucun outil permettant de guider objectivement la sélection des échelles appropriées pour la segmentation, à l'exception de l'outil Estimation des Paramètres d'Échelle (ESP2) (Figure 36).

L'ESP permet une estimation rapide des paramètres d'échelle pour une segmentation multirésolution dans l'environnement logiciel Definiens. ESP, analyse la variance locale (LV) de l'hétérogénéité des objets des images satellite. En nous

appuyant sur les résultats de Kim *et al.* (2008), nous avons utilisé le concept de *LV* (Woodcock et Strahler, 1987) pour créer un outil qui informe sur la sélection des paramètres d'échelle appropriés pour la segmentation dans Definiens Developer.

L'ESP génère itérativement des objets-images à plusieurs niveaux d'échelle dans une approche ascendante et calcule la *LV* pour chaque échelle. La variation de l'hétérogénéité est explorée en évaluant la *LV* en fonction de l'échelle correspondante. Les seuils des taux de changement de *LV* (ROC-*LV*) indiquent les niveaux d'échelle auxquels l'image peut être segmentée de la manière la plus appropriée, par rapport aux propriétés des données au niveau de la scène (Drăguț *et al.*, 2010). L'outil ESP est programmé en Cognition Network Language (CNL) dans le logiciel Definiens Developer, qui est un langage de programmation modulaire pour les applications OBIA (Tiede *et al.*, 2008). Il est implémenté comme un processus personnalisé qui peut être appliqué facilement comme d'autres processus de création d'ensembles de règles basées sur l'objet dans le logiciel Definiens. Six paramètres définis par l'utilisateur sont utilisés : 1) la taille de l'étape de la paramètre d'échelle croissante, 2) paramètre d'échelle de départ pour l'analyse, 3) utilisation d'une hiérarchie d'objets pendant la segmentation, 4) nombre de boucles, 5) pondération de la forme, et 6) pondération de la compacité. Les paramètres (2), (5) et (6) sont décrits par (Baatz et Schape, 2000; Benz *et al.*, 2004) et sont utilisés tels qu'implémentés dans la segmentation multirésolution (Drăguț *et al.*, 2010).




Figure 36 :Segmentation ESP2. Paramètre de segmentation : échelle 20 ; forme 0.05 ; compacité 0.1 ; pondération des bandes de visible : 1 ; pondération des bandes NDVI : 2.

8.3.3 Classification des images

Une classification des données de séries temporelles Sentinel-2 et Landsat-8 a été effectuée dans le but de cartographier l'occupation et l'utilisation du sol dans le delta du fleuve Rouge au Viêt-Nam. Un ensemble de type d'occupation/utilisation des sols d'intérêt a été défini, à savoir : aquaculture, mangroves, riz, légumes, villages, eau et zones humides. La classification s'est faite en se basant sur des algorithmes d'apprentissage automatique RF et MLP.

8.3.3.1 *Random Forest*

Une méthode d'apprentissage d'ensemble bien connue qui combine K arbres CART binaires (arbres de classification et de régression) a été appliquée sur l'ensemble des images. Il s'agit de l'algorithme *Random Forest* (RF) ou forêts aléatoires (Breiman, 2001). Une forêt aléatoire est construite en générant des arbres de décision pour des sous-échantillons de données. Les arbres de décision sont les éléments constitutifs des forêts aléatoires. Par conséquent, les temps de formation et de classification d'un seul arbre de décision sont inférieurs à ceux des forêts aléatoires comportant plusieurs arbres. Les arbres RF sont construits sans élagage et sélectionnent aléatoirement à chaque nœud un sous-ensemble de variables d'entrée. Actuellement, le nombre de variables utilisées pour diviser un nœud RF (noté m) correspond à la racine carrée du nombre de variables d'entrée. Les paramètres correspondants au *Random Forest* sont :

- a) La profondeur maximale de l'arbre (`max_depth`) : ce paramètre contrôle le nombre de couches de l'arbre. Un sous-ensemble de variables (dont le nombre est représenté par le terme m) est choisi, étant inférieur par rapport au nombre de variables, la meilleure division est déterminée sur ce sous-ensemble de variables.
- b) Le nombre minimal d'échantillons dans chaque nœud : ce paramètre détermine la précision de la classification. Plus on utilise de variables, plus les corrélations entre les arbres de décision sont importantes et plus la précision de la classification est élevée (moins de pixels mal classés).
- c) Dans cette application, les valeurs des paramètres utilisées pour *Random Forest* sont les suivantes : Profondeur maximale de l'arbre = 25, Nombre minimal d'échantillons dans chaque nœud = 50 avec un regroupement des valeurs possibles d'une variable catégorielle $k = 8$.

8.3.3.2 Multi-Layer Perceptron (MLP)

Le Multi Layer Perceptron (MLP) qui est un algorithme d'apprentissage supervisé de type linéaire le plus simple de réseau de neurones artificiels a été appliqué pour l'analyse de l'ensemble d'image. Cet algorithme est utilisé pour les classificateurs binaires (séparation de deux classes). Il est composé de plusieurs unités appelées « neurones » organisées en couches : couche d'entrée, couche de sortie, une ou plusieurs couches cachées (*Figure 37*).

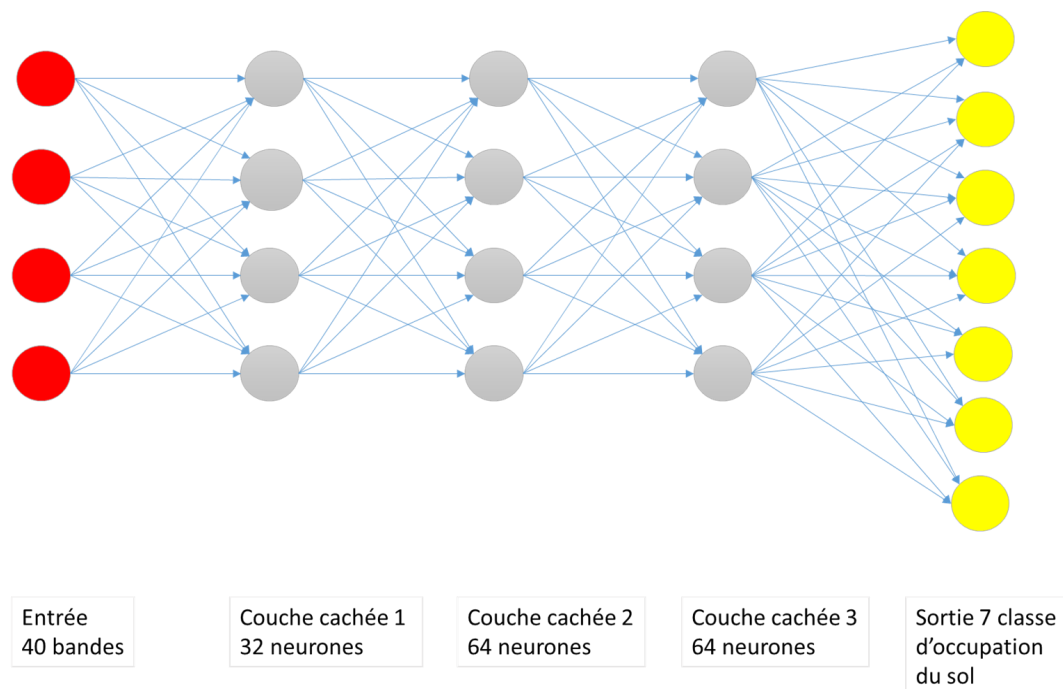


Figure 37 : Modèle MLP

L'ensemble de neurones de la même couche est sans connexion entre eux. Les neurones sont reliés entre eux, de couche en couche, par des connexions pondérées. Ce sont les poids de ces connexions qui régissent le fonctionnement du réseau et qui « programment » une application de l'espace des entrées à l'espace des sorties au moyen d'une transformation non linéaire.

Pour notre application, nous avons opté pour un modèle (*Figure 37*) avec 20 entrées de bandes, 32 neurones sur la première couche cachée, 64 neurones sur la deuxième, 32 neurones sur la troisième et 5 classes sur la couche de sortie. Le processus d'apprentissage passe par deux étapes : l'anticipation et la rétro-propagation.

8.4. Résultats et discussion

Dans le but d'évaluer la performance et l'apport des algorithmes d'apprentissage automatique pour la cartographie de l'occupation et de l'utilisation du sol, une analyse des données de séries temporelles Sentinel-2 et Landsat-8 a été effectuée. La méthodologie et les algorithmes ont été utilisés pour améliorer la précision de la reconnaissance et de la cartographie de l'occupation et de l'utilisation du sol dans le delta du fleuve Rouge au Viêt-Nam.

8.4.1 Résultat des Random Forest

Pour les résultats de l'algorithme *Random Forest*, nous constatons qu'en ce qui concerne la distribution des classes (type) d'utilisation des terres dans le district, les champs agricoles (rizières) situés à l'intérieur des digues couvrent plus de 40% de la surface totale pendant les trois années d'observation. L'eau couvre environ de 23 % à 28 % de la surface et est principalement représentée par la mer, le fleuve Rouge et les rivières Lân et Tra Ly. Les villages, y compris les jardins, couvrent environ 14 % à 15 % des espaces et sont situés au milieu des rizières. Les sols humides ne se trouvent pas vraiment à l'intérieur des digues, sauf au bord des canaux d'irrigation, mais plutôt à l'extérieur des digues, aux embouchures de la rivière Tra Ly au nord et du fleuve Rouge au sud du district. Les mangroves sont identifiées sur les îles dans les estuaires de ces mêmes rivières au cours de 2016, mais elles sont devenues très clairsemées en 2018. En 2018, de nouvelles mangroves ont été plantées autour des bassins d'aquaculture. Les arbustes immergés sont dispersés à l'extérieur des digues, parfois à l'intérieur, couvrent environ 1 à 3 % de la surface. En outre, les marais salants couvrent très peu de territoire, principalement au centre du district et à côté des digues.

D'autre part, les étangs d'aquaculture sont souvent situés à l'extérieur des digues, mais parfois à l'intérieur, et le pourcentage de surface qu'ils occupent n'a pas changé en 2016 mais a augmenté d'environ 5 % en 2017 et 8 % en 2018. Les légumes en général se trouvent souvent dans les basses terres près des rives du fleuve Rouge.

Les résultats montrent une très bonne performance de classification pour toutes les combinaisons (indice de kappa 0,90 et 0,97). En suivant la procédure standard de calcul de la précision (Congalton et Green, 2019), nous avons estimé une précision globale de 93 % (2016), 97 % (2017) et 98 % (2018) et un coefficient de Kappa de 0.90 (2016) et 0,97 (2017 et 2018). Les erreurs de classification par omission et commission ont été constatées principalement dans la classe « légumes » pour 2016 et dans la classe « zones humides » pour les trois années (*Tableau 21*).

Tableau 21 : Précision globale et indice de kappa par classe pour les classifications par forêts aléatoires.

Classe	Précision (%) optique + NDVI 2018	Précision (%) optique + NDVI 2017	Précision (%) optique + NDVI 2018
Rizière	99	100	97
Villages	100	100	100
Eau	100	100	94
Mangroves	100	100	100
Aquaculture	95	95	99
Végétation basse	93	91	47
Zone humide	76	81	71
Kappa index	0.97	0.97	0.90
Précision globale	0.98	0.97	0.93

Par ailleurs, nous constatons que les zones humides sont confondues avec l'aquaculture. En Asie notamment, les bassins d'aquaculture sont dominants à proximité des deltas et des estuaires des fleuves où la culture du riz est également une pratique importante. L'inondation temporaire des champs pendant la saison de culture des rizières et les caractéristiques de forme similaires aux étangs d'aquaculture peuvent créer des erreurs de classification importantes entre ces types lorsque des approches uni-temporelles sont appliquées. Une série chronologique dense d'acquisitions Sentinel-2 et Landsat-8 peut aider à distinguer les plans d'eau temporairement inondés des étangs d'aquaculture inondés relativement stables.

En examinant les changements par les images satellites (*Figure 38*) dans les municipalités du district de Tien Hai nous constatons que ces municipalités présentant les mêmes conditions biophysiques (telles que Nam Phu et Dong Long) ont affiché plusieurs tendances similaires en matière de changement d'utilisation des terres, du fait qu'elles possèdent les mêmes écosystèmes côtiers. De plus, leurs différences sont souvent causées par les activités humaines, à savoir, la fondation récente de Nam Phu contribuant à l'expansion de ses champs agricoles, et la création hâtive de l'aquaculture de Nam Phu encourageant le développement d'étangs et la coupe importante des mangroves. Par ailleurs, les communes ayant des conditions biophysiques différentes (comme Tâỵ Tiên et les communes de Dong Long) n'ont pas les mêmes types d'occupation des sols. En effet, les facteurs physiques et anthropiques n'ont pas le même impact sur les changements d'utilisation des terres.

Nous constatons que, malgré l'enchevêtrement des traitements d'images qui doivent être améliorés, la détection des changements d'utilisation des terres à l'aide des images satellites est très utile. Nous avons pu voir comment chaque type d'utilisation des terres a changé dans le district au cours des années observées afin d'expliquer la relation entre la libéralisation économique et les changements d'utilisation des terres. Ces changements reflètent l'impact des facteurs physiques (tels que les caractéristiques des écosystèmes côtiers qui favorisent les mangroves, les arbustes immergés, les marais salants et la production aquacole) et des facteurs anthropiques (la libéralisation économique, la nouvelle politique de stimulation de l'aquaculture et les plans de développement économique du gouvernement) sur l'utilisation des terres. Les facteurs anthropiques ont un impact plus important sur les changements que les facteurs physiques, notamment dans l'augmentation rapide des étangs d'aquaculture, qui a entraîné à son tour des changements dans les autres types d'utilisation des terres.

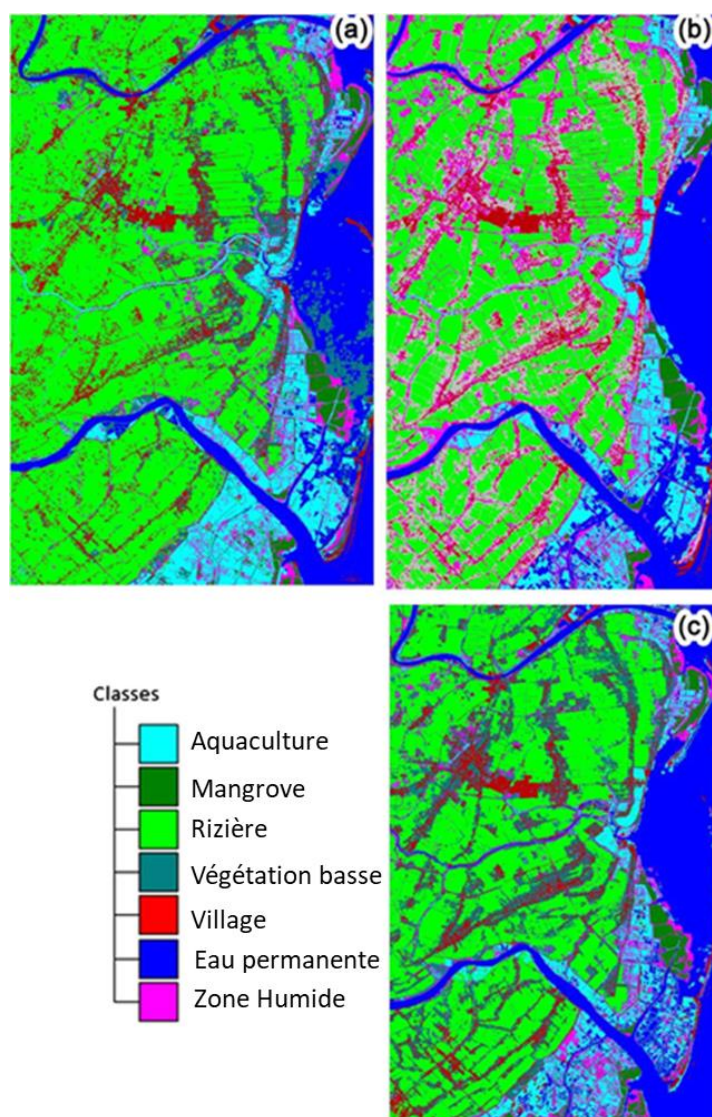


Figure 38 : Occupation du sol en 2016, 2017, 2018 à TienHai, ThaiBinh au Viet-Nam.

8.5. Conclusions

Grâce à son efficacité à détecter les changements d'utilisation des terres et à identifier les catégories elles-mêmes, le traitement d'images effectué par GEOBIA et les algorithmes d'apprentissage automatique dans cette application est adapté à la zone côtière très fragmentée et dynamique du Viêt-Nam. Le traitement d'images montre la dégradation de l'environnement due aux changements d'utilisation des terres, notamment la coupe des mangroves et la disparition des rizières et des marais salants, ainsi que la pollution des bassins d'aquaculture.

Les concepts et méthodes géographiques orientés objet (GEOBIA) ont été appliqués avec succès à l'étude des changements de la couverture terrestre dans le delta du fleuve Rouge, dans le district de Tien Hai. Les tendances émergentes ont été trouvées dans de multiples sous-domaines de GEOBIA, y compris les sources de données, la segmentation d'images, l'extraction de caractéristiques basées sur les objets et les méthodes d'analyse. La segmentation consiste à diviser une image - ou toute donnée matricielle ou ponctuelle - en régions spatialement continues, disjointes et homogènes appelées « segments ». Dans l'extraction de caractéristiques, elle peut être considérée comme une fin en soi. Dans GEOBIA, il s'agit d'une étape dans une chaîne de traitement pour obtenir des « objets significatifs ». Un concept très important pour distinguer GEOBIA des approches de pixel par pixel est la capacité de traiter une multiplicité d'échelles dans une image et sur plusieurs images. L'outil ESP2 a été utilisé pour sélectionner un paramètre qui est unique aux structures du paysage. L'objet de l'image est classé à l'aide de méthodes d'apprentissage automatique (telles que les forêts aléatoires) basées sur un modèle de réseau sémantique et des tactiques de contrôle hybrides (descendantes, ascendantes).

Compte tenu du développement rapide des changements globaux de la zone côtière, avec tous ses effets positifs et négatifs sur les systèmes socio-écologiques dominants, l'approche à faible coût démontrée, basée sur des données open source, est d'une grande pertinence pour tous les aspects, c'est-à-dire la planification, la prise de décision, la gestion et le suivi, d'une gestion intégrée et durable de la zone côtière.

Chapitre 9. Étude et cartographie de l'inondation au niveau du delta du Mékong

La détection et la cartographie de l'étendue des inondations font partie des applications les plus importantes du traitement des données satellitaires. L'identification rapide et précise des zones inondées est essentielle pour soutenir la planification des interventions d'urgence et fournir une évaluation des dommages dans les mesures spatiales et temporelles.

Dans le delta du Mékong, les terres touchées par les inondations sont les rizières. Des études antérieures ont montré que l'identification des rizières touchées par l'inondation n'est pas une tâche facile (Phan *et al.*, 2018), car il faut distinguer les eaux permanentes des eaux de crue. Le delta du Mékong est si important sur le plan écologique, économique et social que de nombreuses études ont été menées au fil des ans à l'aide de données d'observation de la terre pour caractériser la culture du riz. La majorité de ces études se sont concentrées sur la délimitation de la distribution des cultures de riz en utilisant des images satellites optiques (Kontgis *et al.*, 2015; Morinaka *et al.*, 2006) et des images satellites radar (Liew *et al.*, 1998 ; Karila *et al.*, 2014 ; Nguyen *et al.*, 2016 ; Kontgis *et al.*, 2017). Ces dernières années, différentes approches ont été adoptées, notamment le seuillage basé sur l'analyse de la phénologie du riz et l'apprentissage automatique.

Dans ce contexte, l'objectif de cette deuxième application est, d'une part, de cartographier l'étendue et les caractéristiques des inondations et, d'autre part, de cartographier et d'analyser les catégories d'utilisation des sols impactées par les inondations, en l'occurrence les rizières, à l'aide du SAR Sentinel-1A de 2019 et 2020. Ceci en prenant comme cas d'étude la province d'An Giang, dans le delta du Mékong, au Viêt-Nam.

9.1. Méthodologie

Deux algorithmes de classification d'image par apprentissage automatique, à savoir le réseau neuronal convolutif (CNN) et la forêt aléatoire (RF) (*Figure 39*), ont été appliqués en utilisant des données SAR. Ces algorithmes ont été choisis en raison de leurs capacités à dériver des frontières de décision complexes entre les zones inondées et non inondées. Les deux ensembles de caractéristiques, VV et VH, et VV, VH et les trois classificateurs ont été validés par plusieurs mesures de classification et

examinés en matière de leurs performances sur deux groupes d'occupation du sol : les zones inondées et les zones inondables (rizières).

Avant d'expliquer la mise en exécution des algorithmes d'apprentissage automatique choisis, nous tenterons en premier lieu d'expliquer le rapport entre l'utilisation des données SAR et la détection de l'extension de l'inondation, et nous dresserons ensuite la problématique du suivi des rizières par ces données.

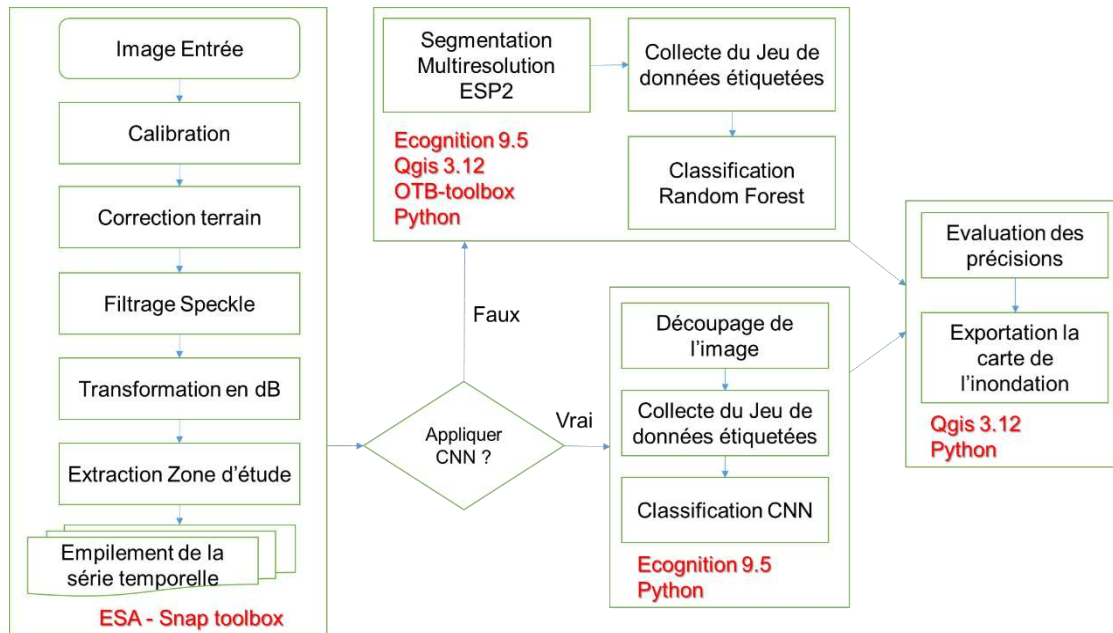


Figure 39 : Prétraitement et traitement d'image SAR Sentinel-1.

9.2. Les données SAR et la détection de l'extension de l'inondation :

Dans l'imagerie SAR, l'eau apparaît généralement comme une surface lisse avec une intensité de rétrodiffusion bien définie. La signature de rétrodiffusion permet de détecter les plans d'eau. Ces derniers constituent un "réflecteur" spéculaire de l'impulsion radar, qui entraîne un signal minimal renvoyé au satellite (Jung *et al.*, 2010 ; Schlaffer *et al.*, 2015). La rugosité de la surface de l'eau, créée par de fortes pluies ou par le vent, peut provoquer une rétrodiffusion du signal radar, ce qui augmente la possibilité que les zones inondées ne soient pas mises en évidence (Alsdorf *et al.*, 2007 ; Jung *et al.*, 2010). La rétrodiffusion du signal SAR varie également en fonction de l'angle d'incidence (IA) (donnée en général par les fournisseurs de production) et des variations de l'angle d'incidence local (LIA) dues à la topographie de la cible et à l'angle d'incidence (Wilusz *et al.*, 2017). L'intensité de la rétrodiffusion peut être influencée par les conditions environnementales telles que la topographie du paysage et les ombres. L'identification de l'extension de l'eau peut être difficile dans les zones

où d'autres objets dépassent et interagissent avec le signal radar. Ainsi, il est difficile de déterminer un seuil général de rétrodiffusion.

En effet, l'environnement peut jouer un rôle très important. Par exemple, l'eau peut être masquée par la végétation. La couverture végétale, lotus et herbes aquatiques, peut être une source d'incertitude dans la cartographie de l'étendue de l'inondation. Selon certains auteurs (Bouvet & Le Toan, 2011), il y a normalement de grandes zones d'herbes aquatiques et de lacs de lotus répandus pendant la saison des inondations. Les types de cultures dominants dans les zones d'étude de la province d'An Giang et de Dong Thap sont le riz et les arbres fruitiers à 2 et 3 saisons. Les données SAR ont la réponse spécifique de rétrodiffusion radar de la végétation structurée verticalement sur un sol inondé ou humide et donc la capacité de distinguer le riz des autres classes de couverture du sol. L'interaction entre une onde électromagnétique radar et la végétation implique principalement trois mécanismes : la réflexion directe (spéculaire), le double rebond, et la diffusion volumique (*Figure 40*).

9.2.1 Le suivi des inondations des rizières :

Le riz est la principale culture dans notre zone d'étude et les rizières peuvent être affectées par des événements d'inondation. La cartographie de l'étendue des inondations est un processus qui permet d'identifier les zones terrestres impactées par la flooding. Dans le même temps, la production de cartes d'utilisation des terres / couverture des terres (LULC) est devenue un moyen fréquent et répandu et apparaît comme un indicateur clé pour le suivi des risques d'inondation (An Thi Ngoc Dang & Lalit Kumar, 2017 ; Mojaddadi *et al.*, 2017). De ce fait, elles peuvent être intégrées dans les bases de données sur les inondations pour réaliser un zonage des lieux à risque et déterminer la vulnérabilité au risque d'inondation.




Figure 40 : Représentation schématique des mécanismes de rétrodiffusion dans la bande C pour le riz (*Oryza sativa*) avec trois phases principales dans le delta du Mékong (phase végétative, phase reproductrice et phase de maturation) : (a) réflexion directe (spéculaire) ; (b) double rebond ; et (c) diffusion volumique.

Au cours de la première période (phase végétative), les rizières sont recouvertes d'eau pendant la majeure partie de leur cycle de croissance. Les champs ne sont inondés que pendant certaines périodes (émergence et tallage de la phase végétative et booting, épiaison pour la phase reproductive). Le sol reste humide (non inondé) pendant le début du tallage et l'élongation et l'initiation de la panicule pour la phase reproductive et pendant la phase de maturation (maturation). La rétrodiffusion radar des champs inondés est faible en raison de la réflectance spéculaire de la surface de l'eau.

Pendant la période de croissance, du stade végétatif au stade reproductif, la rétrodiffusion radar est plus importante. La rétrodiffusion radar augmente rapidement, ce qui est une conséquence de l'augmentation rapide de la hauteur (jusqu'à 100 cm) et de la biomasse des plants de riz. Le principal mécanisme de rétrodiffusion à cette période est le double rebond. La phase reproductive suivante comprend l'initiation de la panicule, l'épiaison et la floraison. Pendant cette phase, les plantes cessent d'augmenter en hauteur et en biomasse. La maturation est la phase finale avec ses processus de lait, de pâte et de grain mûr et c'est la diffusion de volume qui caractérise cette phase.

9.3. Zone d'étude

Le Mékong est le septième plus long fleuve d'Asie et le douzième plus long du monde. Son delta couvre une superficie de près de 40 000 Km² dans 12 provinces et municipalités habitées par près de 18 millions de personnes, soit 20% de la population du pays.

Dans le but d'évaluer et cartographier le risque d'inondation, deux provinces qui se situent dans le delta du Mékong ont été choisies : An Giang et Dong Thap (*Figure 41*) situées entre 8,5°-11,5°N et 104,5°-106,8°E. Le modèle économique dans ces provinces est essentiellement basé sur l'agriculture, la pêche et le commerce avec l'existence de véritables marchés flottants. La pêche est également une activité très importante pour les habitants de la région. Elle est à la fois une source de revenus pour la population locale.

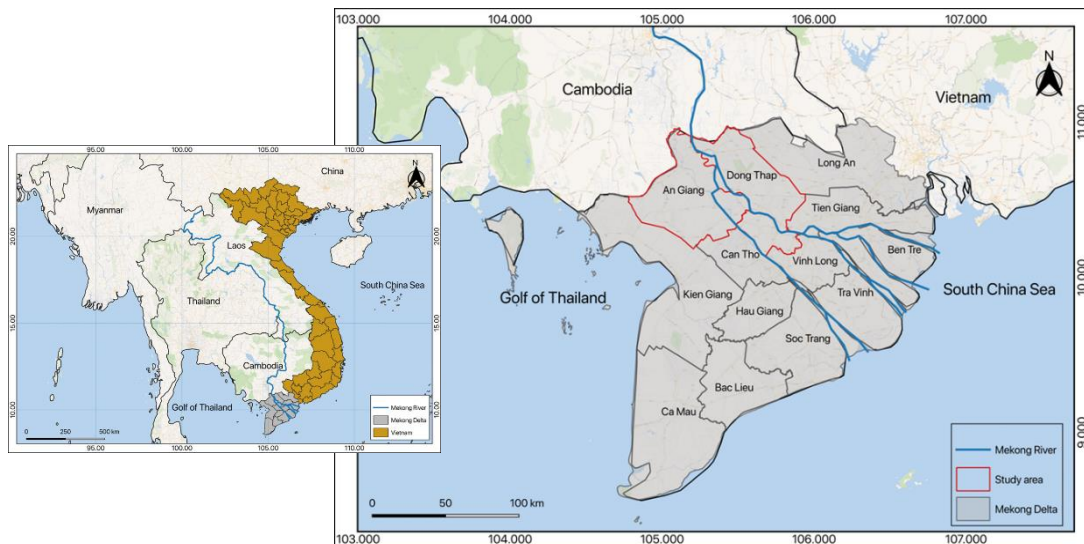


Figure 41 : Zone d'études - Province AnGiang et Province DongThap au delta du Mékong.

9.3.1 La culture du Riz au delta du Mékong

Le delta du Mékong est une vaste plaine inondable et l'une des zones agricoles les plus fertiles d'Asie. En effet, le sud du Viêt-Nam est une grande région agricole, qui est spécialisée dans la culture du riz. En 2020, malgré la sécheresse et la salinisation, le delta du Mékong, grenier du Viêt-Nam, a produit 24 millions de tonnes de riz à partir de ses 1,5 million d'hectares de terres cultivées, soit un rendement moyen par hectare de 6 tonnes. En 2020, les exportations de riz du delta du Mékong s'élevaient à 6 millions de tonnes. (Le Courrier du Viêt-Nam, 27/05/2021). Le delta du Mékong possède des écosystèmes rizicoles principalement irrigués avec trois saisons de culture principales : saison de culture hiver-printemps, été-automne et automne-hiver (Thi Hoa Phan, 2018). Par rapport à la saison des pluies et des inondations, nous nous intéressons davantage à la saison culturale automne-hiver. Selon le calendrier de la riziculture de cette saison, le riz est planté en juillet-août, et récolté en décembre-janvier. Selon Thi Hoa Phan, 2018, la culture d'automne-hiver pendant la saison des pluies a la productivité la plus faible.

9.3.2 Régime hydro-météorologique du Mékong

Le régime pluviométrique de la région est caractérisé par une alternance entre les saisons sèches et humides. La période des inondations a lieu entre juin et novembre. Elle coïncide avec l'arrivée de la mousson, un vent chaud et humide venant de l'équateur et qui donne des pluies abondantes dans toute cette région d'Asie du Sud-Est. Cette mousson est renforcée par le différentiel de température entre le continent et l'océan. La région peut enregistrer des précipitations allant jusqu'à 2000 mm par an. La quantité de pluie qui tombe dans la région est très variable dans le

temps et dans l'espace. D'un mois à l'autre, la quantité de pluie enregistrée peut doubler.

Le bas du delta du Mékong, avec ses rivières, est influencé par la mousson d'Asie du Sud-Est. Le régime hydrologique présente de très grandes variations annuelles et interannuelles. La mousson, avec théoriquement une saison sèche et une saison des pluies (maximum en juillet) donne lieu à des précipitations à la mi-avril, s'il n'y a pas de dégel, le tout avec de fortes variations d'une année sur l'autre en fonction de la force de la mousson humide. Ensuite, les précipitations de convergence prolongent la saison des pluies ; plus constantes, elles ajoutent des inondations d'octobre à novembre. Et enfin, les typhons, qui génèrent le potentiel hydrique maximal en novembre-décembre. Les inondations les plus fréquentes dans le delta sont principalement induites par le régime des crues du Mékong ainsi que par l'écoulement de surface. La construction de systèmes de digues à partir du début des années 1990 pour protéger les champs des inondations et permettre une troisième culture dans certaines parties du delta, contribue à des perturbations du système hydrologique. Ce n'est pas le cas partout dans notre zone d'étude.

9.4. Données utilisées

9.4.1 Les données satellitaires

Pour la surveillance des inondations et l'étude de l'humidité des sols, les données SAR, avec leur capacité à pénétrer les nuages, est une source d'information intéressante. Les données Sentinel-1 avec leur résolution temporelle plus élevée que les instruments SAR précédents, sont capables de suivre le cycle saisonnier de l'étendue des eaux tous les six jours. En effet, les données satellitaires utilisées dans cette étude sont des images du satellite radar Sentinel-1 de l'Agence spatiale européenne (ESA). Lancée en 2015, la mission comprend deux satellites déphasés et placés en orbite polaire. Ces satellites (Sentinel-1A et Sentinel-1B) qui partagent le même plan orbital génèrent des données dans le domaine des micro-ondes (grande longueur d'onde ou hyperfréquences) en bande C avec une longueur d'onde d'environ 4,5 cm. Les images ont été téléchargées depuis la plate-forme Copernicus du Hub de l'ESA. Elles sont en GRD (intensité et amplitude) et sont obtenues à partir d'images SLC, sur une période de 6 mois (du 6 juin au 30 novembre). Cette dernière correspond à la période d'inondation dans la région du delta du Mékong. La résolution temporelle des données Sentinel-1 est de 6 jours, ce qui correspond à l'acquisition de 30 images.

Les deux satellites Sentinel-1 sont placés sur la même orbite à environ 900 km de la surface de la Terre. Leur déphasage permet une meilleure résolution temporelle. Ces images en bande C et de longueur d'onde d'environ 4,5 cm sont acquises en deux polarisations VH et VV. La polarisation est l'orientation des champs électromagnétiques de la longueur d'onde.

Sentinel-1 génère pour chaque acquisition deux bandes avec une polarisation verticale en émission et horizontale en réception, et l'autre verticale en émission et en réception. La polarisation de Sentinel-1 est également appelée polarisation monochromatique, ce qui signifie que nous aurons toujours les mêmes amplitudes et les mêmes longueurs d'onde. Les données sont acquises sur l'orbite N° 18 qui passe au-dessus du delta du Mékong. Le numéro de l'orbite est un paramètre important car il permet d'avoir des images sur la même zone d'étude et au même moment. Cependant, les orbites ascendantes ou descendantes permettent l'acquisition. La direction de l'orbite est un paramètre important à prendre en compte pour une meilleure interprétation des images.

Les caractéristiques des tirs (angles d'incidence) auront également un impact sur l'interprétation des images. En effet les images de Sentinel-1 sont acquises avec un angle d'incidence compris entre 30 et 45°, ce qui veut dire que les premiers pixels de la plage proximale sont à 30° et les derniers pixels de la plage distale sont observés avec un angle d'incidence de 45°. Cela signifie que deux objets géographiques de même nature peuvent avoir une rétrodiffusion différente en fonction de leur angle d'acquisition. Cela peut poser des problèmes d'interprétation des surfaces étudiées, surtout lorsqu'on travaille sur l'ensemble de l'image.

9.4.2 Données environnementales

Afin de comparer les valeurs des images radar avec les précipitations, les données quotidiennes de quatre stations météorologiques de 2019 à 2020, notamment celles relatives à la précipitation, ont été téléchargées depuis la plateforme NOAA : <https://www7.ncdc.noaa.gov> et le niveau d'eau du Mékong depuis la Mekong River Commission <https://www.mrcmekong.org/>.

9.5. Méthode d'apprentissage automatique et classification

9.5.1 Segmentation d'images et extraction de caractéristiques

La segmentation est définie comme le processus de division des images en objets homogènes, en prenant en considération leurs caractéristiques spectrales et spatiales (Drăguț *et al.*, 2010). Dans cette application, l'algorithme de segmentation multi-résolution (MRS) (Baatz et Schape, 2000) a été utilisé. Il s'agit d'un algorithme robuste et largement utilisé dans le domaine de la segmentation d'image. Implémenté dans le logiciel ECognition® (Trimble Geospatial Imaging), la segmentation multi-résolution est une technique de fusion de régions d'intérêt afin d'obtenir des séparations qui maximisent la variabilité inter-objet, tout en minimisant la variabilité intra-objet.

Quatre paramètres sont étudiés pour la réalisation de la segmentation : un paramètre d'échelle, le poids attribué à chacune des couches étudiées, le poids attribué à la valeur spectrale et à la forme des associations de pixels ainsi que le poids attribué à la compacité et à la rugosité des régions.

Le paramètre d'échelle, utilisé pour déterminer la taille finale de l'objet, correspond à l'hétérogénéité maximale autorisée pour la création d'un objet (Liu *et al.*, 2018). La MRS s'appuie sur un contrôle clé pour partitionner une image en objets d'image, il s'agit de la nouvelle estimation du paramètre d'échelle (ESP2). L'algorithme de segmentation ESP est basé sur l'exploitation d'un paramètre de variance locale (LV). Ce paramètre est capable de détecter les transitions d'échelle dans les données géospatiales. La valeur du paramètre de variance locale est calculée à chaque itération et sert de condition pour terminer le processus de segmentation : l'itération se termine et les objets de la couche concernée sont segmentés lorsque la valeur de VL d'une couche concernée est égale ou inférieure à la valeur de l'itération précédente (Drăguț *et al.*, 2014).

Les CCNs sont devenus populaires en raison de leur capacité à résoudre des problèmes de classification tels que la reconnaissance d'images et la classification de séries temporelles. LeCunet *al.*, 1989 ont obtenu de très bons résultats en proposant un réseau de neurones convolutifs à partir d'un modèle appliquant la rétropropagation. L'idée de développer des réseaux de neurones convolutifs était initialement basée sur la connectivité locale, dans laquelle chaque nœud est connecté uniquement à une région locale de l'entrée (Borovykh *et al.*, 2017). Le réseau résultant possède de nombreuses connexions mais relativement peu de paramètres libres.

9.5.2 Construction du modèle du CNN

L'architecture des CNNs est une structure comportant une série de couches : couche convolutive, couche de regroupement, couche de perceptron. Les réseaux de neurones convolutifs (CNNs) que nous proposons sont constitués de deux couches convolutives et deux couches de regroupement (Max pooling layer) (Figure 42).

Les unités d'une couche convolutive sont organisées en cartes de caractéristiques (feature-maps) dans lesquelles chaque unité est connectée aux patches locaux dans les cartes de caractéristiques de la couche précédente par des matrices de poids partagées appelées banques-filtres (filter-bank). La taille habituelle d'un filtre est de 3×3 , 5×5 ou 7×7 pixels. Dans ce travail, le filtre 3×3 a été appliqué.

Le processus de convolution des matrices est répété sur les cartes neuronales (neural maps) construites pour créer de nouvelles couches cachées profondes. La couche de regroupement (pool-layer) a pour rôle de fusionner les caractéristiques de la fenêtre en un pixel par des opérations de maximum ou de moyenne.

Après une couche de regroupement, les cartes de caractéristiques sont réduites en taille mais leurs caractéristiques de base sont conservées pour l'étape suivante. Un réseau neuronal convolutif compare les images fragment par fragment. Les fragments recherchés sont appelés caractéristiques. Le réseau neuronal convolutif recherche les caractéristiques approximatives qui sont à peu près similaires dans deux images différentes, plutôt que de procéder à une comparaison complète image par image.

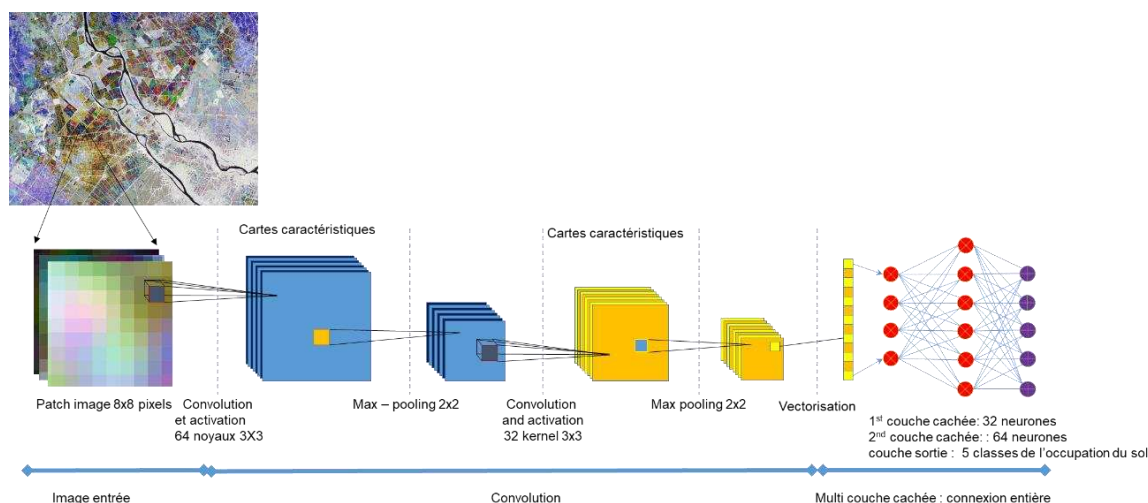


Figure 42 : Classificateur CNN généralisé avec l'architecture 2D-CNN.

D'après Kim, 2017, les réseaux neuronaux convolutifs peuvent être considérés comme des réseaux neuronaux artificiels multicouches feedforward entraînaibles, qui comprennent plusieurs étapes d'extraction de caractéristiques. Les couches convolutives caractérisent chaque étape d'extraction de caractéristiques avec des

filtres d'apprentissage, des couches de mise en commun et des fonctions d'activation ou des couches de non-linéarité (Gebrehiwot, 2019). Un autre élément important dans l'ensemble du processus est l'unité linéaire rectifiée ou ReLU, qui remplace les valeurs négatives du réseau en cours de formation par un zéro.

9.5.3 *Random Forest (RF)*

L'algorithme *Random Forest* (RF) a été appliqué pour la classification des zones d'inondation et des zones inondables, en utilisant le logiciel libre Orfeo ToolBox (OTB), dans sa version intégrée à QGIS. Ce classificateur construit par Breiman (2001) est un algorithme non paramétrique d'apprentissage automatique basé sur les arbres de décision. Il est fréquemment utilisé pour la classification d'images SAR, que ce soit en zone forestière (Balzter *et al.* 2015 ; Rüetschi *et al.*, 2018) ou en zone de culture (Ghazaryan *et al.*, 2018). Il a l'avantage de ne pas être influencé par le problème du sur-apprentissage qui se produit lorsqu'un modèle est trop basé sur les échantillons d'entraînement.

La profondeur des arbres et la taille minimale de l'échantillon sont les deux paramètres les plus importants du classificateur RF. Dans ce travail, le nombre d'arbres a été fixé à 500 et le nombre de caractéristiques dans un sous-ensemble était la racine carrée du nombre total de caractéristiques. Afin d'entraîner et de valider le modèle sur des ensembles d'échantillons indépendants, nous avons divisé aléatoirement la base de données des échantillons, ou 70% pour le processus de l'entraînement de l'algorithme et 30% pour la validation des résultats.

9.5.4 Évaluation de la précision

Pour évaluer la pertinence des modèles d'apprentissage automatique appliqués, nous avons exécuté un processus de validation en calculant une matrice normalisée (Olofsson, 2014). Nous avons normalisé la matrice de confusion par la proportion du nombre de points de contrôle et par la proportion des classes de surface obtenues dans la classification. En effet, à partir des points de validation, nous avons normalisé la matrice d'erreur brute pour générer des statistiques communes à l'aide des métriques telles que la précision globale (Overall Accuracy), la précision du producteur (Producer Accuracy) et la précision de l'utilisateur (User Accuracy). Une évaluation de la performance des classifications résultante a été effectuée pour les trois algorithmes.

Plusieurs études fournissent également un intervalle de confiance pour une estimation ponctuelle de la précision (Niculescu et al, 2020). Un choix courant est un intervalle de confiance de 95 % (Olofsson et al, 2014 ; Stehman & Foody, 2019). Dans les évaluations de la précision de la couverture terrestre, la méthode standard pour construire un intervalle de confiance consiste à supposer une distribution normale ou une estimation ponctuelle avec un écart-type égal à l'estimation résultante de la marge d'erreur, c'est-à-dire la racine carrée de la variance estimée divisée par la taille de l'échantillon (Newcombe, 1998). Dans cette étude, les calculs des intervalles de confiance ont été automatisés dans le script python inclus dans QGIS.

9.6. Résultats

9.6.1 Profils de rétrodiffusion de rizières

En corrélation avec les précipitations quotidiennes pendant deux ans (2019, 2020) enregistrées à la station hydrométéorologique de Tan Chau et partant du principe que le signal RADAR est sensible à l'humidité de surface, nous avons analysé le coefficient de rétrodiffusion de quelques rizières de référence. Ces analyses se sont effectuées dans deux périodes, pendant la saison sèche et pendant la saison humide (rizière inondée et rizière non inondée). Les données hydrométéorologiques ont été interprétées en corrélation avec les saisons rizicoles et les observations du satellite SAR Sentinel-1 (60 images par an, 5 images par mois) et avec les niveaux d'eau du Mékong enregistrés à la même station et sur les deux années.

Les niveaux d'eau du fleuve Mékong commencent à augmenter à partir de juin, parallèlement à l'augmentation des précipitations, avec un maximum de 70 mm le 1^{er} août 2020. Les précipitations déterminent l'augmentation des niveaux d'eau du Mékong entre juin et novembre des deux années avec un maximum de près de 3 m pour 2020 et 3,5 m pour 2019 en raison des précipitations abondantes de la même période.

Les valeurs de rétrodiffusion sont les plus faibles pour VH (b), légèrement plus élevées pour VV (c) en 2020. VH a la plus grande amplitude et présente des pics de rétrodiffusion importants, notamment pour la rizière inondée. La variation des valeurs du coefficient de rétrodiffusion montre l'influence de l'humidité de surface sur le signal radar, notamment pour la saison humide et pour les rizières inondées. Par exemple, à partir de juin, les valeurs du coefficient de rétrodiffusion sont très faibles pour la rizière inondée avec des valeurs comprises entre -25 et -30db en VH et entre -20 et -25db en

VV (*Figure 43*). Le coefficient a montré des valeurs faibles jusqu'à la fin de la saison humide (jusqu'en novembre) pour la rizière inondée. La saison rizicole automne-hiver est dominée dans certaines zones par les inondations et cette saison peut donc être considérée comme moins productive. La période d'inondation qui coïncide avec la saison du riz d'automne-hiver doit être considérée comme une période de "repos" dans le cycle de croissance du riz, comme une période avec une production de riz réduite.

En saison sèche pour les deux rizières différentes et en saison humide pour la rizière non inondée, la variation du coefficient en VH et VV des deux rizières différentes s'explique par la phénologie différente du riz sur les deux rizières.

Un cycle du riz comporte généralement trois grandes étapes : la phase végétative, la phase reproductive et la phase de maturation. Avant le repiquage, les rizières sont généralement inondées pendant plusieurs semaines pour préparer le sol (rendre le sol très meuble et niveler le champ). Le riz est ensuite planté dans un sol inondé sous 2 à 5 cm d'eau. Les valeurs de rétrodiffusion VH et VV étaient relativement faibles pendant cette période de repiquage (décembre à janvier (entre -20 et -22db pour la VH et entre -15 et -20db pour la VV) pour la première culture et juillet à août pour la deuxième culture (-27 n VH et -25db en VV)) en raison de la surface lisse de l'eau (réflexion directe (spéculaire)).

Après le repiquage, les plants de riz ont commencé à croître en développant des talles et des feuilles, "l'initiation des panicules". A ce stade, la hauteur des plantes et la biomasse deviennent importantes. Le plant de riz atteint le stade d'épiaison lorsque la panicule est entièrement visible. En cette période l'intensité de la rétrodiffusion pour les deux polarisations augmente en février-mars (-12db pour les deux polarisations) et en juin-juillet (-11db en VH et -6db en VV) en raison des changements de la rugosité de la surface de la rizière. Le riz présente deux pics, indiquant respectivement les deux dates d'épiaison de la première et de la deuxième récolte. Le premier pic se situait souvent entre fin mai et début juin, tandis que le deuxième pic apparaissait en octobre. La phase de floraison a commencé après la fin de la phase d'épiaison, caractérisée par l'arrêt du développement de la hauteur de la plante et de la biomasse, et la réduction de la teneur en eau des feuilles et de la tige. Par conséquent, l'intensité des valeurs de rétrodiffusion a également diminué. Après la récolte, les rizières de la période de jachère étaient soit nues, soit faiblement couvertes de mauvaises herbes, ce qui a entraîné une diminution significative des valeurs de rétrodiffusion (-25db en VH et -20db en VV pour début mars et -27db en VH et -20db en VV pour début août). D'une manière générale, VH et VV montrent pour

les rizières non inondées une augmentation des valeurs des coefficients de rétrodiffusion pour la période végétative et reproductive des trois saisons rizicoles, et deux saisons rizicoles pour la rizière inondée.




Figure 43 : Profil temporel VH et VV a) Pluies quotidiennes et niveaux d'eau quotidiens du Mékong enregistrés à la station hydrométéorologique de Tan Chau en 2020. Saisons des trois cycles du riz (saison du riz hiver-printemps, été-automne et automne-hiver). Observations de SAR Sentinel-1 : 60 images pour 2020 ; b) Profils temporels VH de rizières non inondées pendant la saison humide et de rizières inondées pendant la saison humide ; c) Profils temporels VV de rizières non inondées et de rizières inondées pendant la saison humide.

Selon les Figures 43 et 42, la saison des pluies en 2019 commence plus tard (fin juin) et se termine plus tôt (en novembre). Par ailleurs, les précipitations maximales ne dépassent pas 45 mm et les quantités les plus importantes ont été enregistrées à partir du mois d'août. Le niveau maximum d'environ 3,5 m a été enregistré à la mi-septembre. Les valeurs de rétrodiffusion sont les plus faibles pour VH (b), légèrement plus élevées pour VV (c) en 2019, tout comme en 2020. Les valeurs élevées du coefficient de rétrodiffusion correspondent à une rizière au développement végétatif




Figure 44 : a) Pluies quotidiennes et niveaux d'eau quotidiens du Mékong enregistrés à la station hydrométéorologique de Tan Chau au cours de l'année 2019. Saisons des trois cycles rizicoles (saison rizicole hiver-printemps, été-automne et automne-hiver). Observations des observations SAR Sentinel-1 : 60 images pour 2019 ; b) Profils VH temporels de la rizière non inondée pendant la saison humide et de la rizière inondée pendant la saison humide ; c) Profils VV temporels de la rizière non inondée pendant la saison humide et de la rizière inondée pendant la saison humide.

avancé (valeurs d'activité chlorophyllienne élevées). Pour toutes les rizières de référence, en 2020, le coefficient de rétrodiffusion a augmenté progressivement

pendant la phase de croissance du riz au cours des trois saisons pour les rizières non inondées, et des deux saisons pour les rizières inondées. Les deux polarisations illustrent cette sensibilité du signal RADAR à la croissance du riz. Par ailleurs, nous constatons également que le signal RADAR est sensible au moment de la récolte. En effet, une diminution du signal a été observée après la récolte (*Figure 44*).

9.7. Validation et comparaison des modèles

9.7.1 L'évaluation de la précision du modèle CNN

Pour évaluer la performance du modèle CNN, des paramètres statistiques de précision (OA et PA et UA) ont été calculés en utilisant des données de validations. Ainsi la précision globale (OA) par mois pour la saison humide (tableau 22) la précision de la production (PA) (*Tableau 23*) et la précision de l'utilisateur (UA) par mois pour la saison humide (tableau 24) ont été estimées pour les deux années 2019 et 2020.

Tableau 22 : Comparaison des précisions globales par le modèle CNN chaque mois pendant la saison humide en 2019 et 2020.

Mois	Précision globale	
	2019	2020
Juin	99.81 ± 0.01	99.66 ± 0.01
Juillet	99.31 ± 0.03	99.68 ± 0.01
Août	99.13 ± 0.02	99.62 ± 0.01
Septembre	98.67 ± 0.02	99.87 ± 0.01
Octobre	98.67 ± 0.02	99.51 ± 0.01
Novembre	98.64 ± 0.02	96.51 ± 0.03
Décembre	99.09 ± 0.01	99.35 ± 0.01

Tableau 23 : Précisions de l'utilisateur par le modèle CNN chaque mois pendant la saison humide en 2019 et 2020

Mois	Précision de l'utilisateur			
	2019		2020	
	inondée	Non-inondée	inondée	Non-inondée
Juin	99.26 ± 0.02	99.83 ± 0.01	99.70 ± 0.01	99.66 ± 0.01
Juillet	99.85 ± 0.02	99.29 ± 0.03	99.39 ± 0.03	99.68 ± 0.01
Août	99.89 ± 0.01	99.09 ± 0.02	96.01 ± 0.06	99.78 ± 0.01
Septembre	97.98 ± 0.07	98.82 ± 0.02	99.61 ± 0.03	99.88 ± 0.01
Octobre	98.37 ± 0.03	99.99 ± 0.00	98.32 ± 0.04	99.87 ± 0.00
Novembre	97.08 ± 0.05	99.12 ± 0.01	88.66 ± 0.10	99.62 ± 0.01
Décembre	90.20 ± 0.08	99.52 ± 0.01	97.53 ± 0.06	99.64 ± 0.01

Tableau 24 : Précisions du producteur par le modèle CNN chaque mois pendant la saison humide en 2019 et 2020.

Mois	Précision du producteur			
	2019		2020	
	inondée	Non-inondée	inondée	Non-inondée
Juin	94.78 ± 0.2	99.98 ± 0.00	99.70 ± 0.01	99.66 ± 0.01
Juillet	79.80 ± 0.62	100.0 ± 0.00	99.39 ± 0.03	99.68 ± 0.01
Août	85.08 ± 0.26	99.09 ± 0.02	96.01 ± 0.06	99.78 ± 0.01
Septembre	99.98 ± 0.00	99.31 ± 0.02	99.61 ± 0.03	99.88 ± 0.01
Octobre	97.73 ± 0.04	99.16 ± 0.02	98.32 ± 0.04	99.87 ± 0.00
Novembre	97.08 ± 0.05	99.12 ± 0.01	88.66 ± 0.10	99.62 ± 0.01
Décembre	90.20 ± 0.08	99.52 ± 0.01	97.53 ± 0.06	99.64 ± 0.01

9.7.1.1 Analyse de la précision du producteur

En général, les PA par mois de la saison des pluies pour les zones inondées sont inférieurs aux PA des zones non inondées. Cette tendance se vérifie pour les deux années. En 2019, les valeurs de PA des zones inondées pour les 7 mois observés varient de 79,8% (en juillet) à 97,73 (septembre et octobre). En effet, durant cette année 2019, le mois de juillet correspond à l'extension minimale des zones

inondées tandis que les mois de septembre et octobre correspondent à l'extension maximale. Pour les zones non inondées, les erreurs d'Omission en 2019 vont de 99,09% pour l'un des mois les plus inondés (novembre) à 100% pour le mois le moins inondé (juillet).

Ainsi, on remarque qu'en 2020, les valeurs de l'AP pour les zones inondées par mois suivent la même logique, avec les valeurs les plus faibles pour les mois d'extension moindre des zones inondées (juillet 88,34%) et les valeurs les plus élevées pour les mois d'extension maximale des zones inondées (octobre avec 99,59% puis novembre avec 98,92%). Durant la même année 2020, la tendance des valeurs de PA est la même, en effet, des valeurs élevées, 99,99% pour le mois de juin et 99,48% pour le mois d'octobre qui marque plus d'inondation.

9.7.1.2 *Analyse de la précision de l'utilisateur:*

Selon les résultats du tableau 22, les valeurs de l'UA sont plus cohérentes et plus élevées pour les zones non inondées que pour les zones inondées pour les deux saisons des deux années. En effet, on note qu'en 2019, des valeurs faibles (90,20 %) ont été enregistrées pour la période de décembre à la fin de la saison humide, c'est-à-dire les mois qui ont marqué moins d'inondation, tandis que ces valeurs de UA sont plus élevées (99,89 %) pour le mois d'août, considéré comme un mois intermédiaire pour le phénomène de l'inondation. Des UA supérieures à 99% ont été constatés dans le cas des zones non inondées en 2019, et ce, pour tous les mois sauf ceux avec une extension maximale des zones inondées (octobre et novembre avec des valeurs supérieures à 98%).

En 2020, dans le cas des zones inondées, les valeurs les plus faibles (88,66%) ont été enregistrées durant le mois d'extension maximale des inondations (en novembre). La valeur la plus élevée (99,70%) de l'UA est atteinte au mois de juin avec très peu d'inondations. En ce qui concerne les zones non inondées, les valeurs de l'UA sont sans exception supérieures à 99% avec un maximum en septembre et un minimum en novembre.

9.7.2 *L'évaluation de la précision du classificateur RF*

Pour évaluer la performance de l'algorithme RF, les paramètres statistiques, précision globale OA (*Tableau 25*), précision de l'utilisateur (*Tableau 26*) et précision de producteur (*Tableau 27*), ont été calculés en utilisant des données de validations.

Les résultats suivant les calculs de l'AO et leurs intervalles de confiance appliquant les classifications du modèle RF pour la série temporelle S1 montrent la différence de la précision du classificateur RF pour les mois de la saison humide (Tableau 25).

Tableau 25 : Comparaison des précisions globales par le modèle RF chaque mois en de la saison humide en 2019 et 2020.

Mois	Précision globale	
	2019	2020
Juin	99.68 ± 0.01	99.35 ± 0.01
Juillet	98.87 ± 0.02	99.53 ± 0.01
Août	97.92 ± 0.03	98.86 ± 0.01
Septembre	99.43 ± 0.01	98.85 ± 0.02
Octobre	97.18 ± 0.03	95.04 ± 0.03
Novembre	94.98 ± 0.03	93.26 ± 0.04
Décembre	92.53 ± 0.02	98.20 ± 0.02

Tableau 26 : Précisions de l'utilisateur par le modèle RF pour les mois de la saison humide en 2019 et 2020.

Mois	Précision de l'utilisateur			
	2019		2020	
	inondée	Non-inondée	inondée	Non-inondée
Juin	97.97 ± 0.04	99.73 ± 0.01	93.90 ± 0.06	99.64 ± 0.01
Juillet	89.84 ± 0.12	99.44 ± 0.02	98.39 ± 0.04	99.57 ± 0.02
Août	99.75 ± 0.02	97.82 ± 0.03	93.41 ± 0.08	99.16 ± 0.01
Septembre	96.89 ± 0.09	99.92 ± 0.00	98.62 ± 0.06	98.86 ± 0.02
Octobre	97.48 ± 0.04	97.04 ± 0.03	84.15 ± 0.11	99.72 ± 0.01
Novembre	86.10 ± 0.09	98.80 ± 0.02	81.45 ± 0.12	99.60 ± 0.01
Décembre	62.05 ± 0.10	99.52 ± 0.01	97.02 ± 0.06	98.42 ± 0.02

Tableau 27 : Précisions du producteur par le modèle RF pour les mois de la saison humide en 2019 et 2020.

Mois	Précision du producteur			
	2019		2020	
	inondée	Non-inondée	inondée	Non-inondée
Juin	91.42 ± 0.26	99.94 ± 0.00	93.23 ± 0.18	99.68 ± 0.00
Juillet	91.18 ± 0.30	99.35 ± 0.01	90.43 ± 0.31	99.93 ± 0.00
Août	71.22 ± 0.27	99.99 ± 0.00	85.99 ± 0.17	99.64 ± 0.00
Septembre	99.59 ± 0.03	99.40 ± 0.02	82.43 ± 0.24	99.92 ± 0.00
Octobre	93.88 ± 0.07	98.81 ± 0.02	99.24 ± 0.02	93.60 ± 0.04
Novembre	96.88 ± 0.04	94.29 ± 0.03	99.10 ± 0.02	90.91 ± 0.05
Décembre	96.72 ± 0.07	91.96 ± 0.02	92.06 ± 0.11	99.43 ± 0.01

9.7.2.1 Analyse de la précision globale :

En 2019, une précision globale supérieure à 99% a été obtenue pour le mois de juin tandis qu'en 2020 cette précision a été notée pour les mois de juin et juillet. Par ailleurs, on note qu'avec le classificateur CNN, la précision la plus faible était de 96% (novembre 2020), alors qu'avec le classificateur RF, les précisions les plus faibles sont entre 92% (décembre 2019) et 93% (novembre 2020). En revanche, les deux algorithmes de classification ont obtenu une précision globale supérieure à 92%, sauf que la précision globale obtenue par le modèle CNN est supérieure à celle obtenue par les classificateurs RF. Ainsi, la performance de classification globale montre que le modèle CNN obtient une meilleure classification que le RF, pour tous les mois de la période d'inondation.

9.7.2.2 Analyse de la précision de producteur :

Les PA (Tableau 27) pour les deux années des zones inondées, sont inférieurs aux PA des zones non inondées. On constate la même chose pour l'application du CNN. Il y a deux exceptions, les PA de novembre et décembre pour les zones inondées en 2019 sont plus élevés par rapport aux PA des zones non inondées : 96,88% et 94,29% en novembre et 96,72% et 91,96% en décembre. Cette valeur de 96,72% au mois de décembre 2019 obtenue suite à l'application de la RF est même supérieure au PA du CNN pour le même mois et la même année (89,99%). Une situation similaire se présente pour le mois de juillet 2019, durant lequel la valeur du PA est plus faible avec le CNN qu'avec l'application de la RF (79,80% et 91,18%).

Avec ces exceptions, en général, les PA obtenus suite à l'application du CNN sont plus élevés pour les deux années et pour les deux classes majeures que les PA obtenus suite à l'application du RF.

9.7.2.3 Analyse de la précision de l'utilisateur:

Les valeurs de l'UA (*Tableau 26*) sont significativement plus faibles pour les zones inondées par rapport aux zones non inondées pour les deux années. Au mois de décembre 2019, nous avons obtenu la valeur minimale de 62,05% pour les zones inondées alors qu'avec le CNN nous avons obtenu 90,20%. Des valeurs inférieures ont également été enregistrées en 2020 pour les mois d'octobre et de novembre (84,15% et 81,45%). L'UA maximale était obtenu au d'août 2019, qui atteignait 99,75% pour les zones inondées et 99,72% en octobre 2020 pour les zones non inondées, alors qu'avec le CNN la valeur maximale de l'UA pour les zones inondées est toujours notée pour le mois d'août (99,89%).

9.8. Résultats des modèles : cartographie inondée et inondable

9.8.1 Cartographie de l'étendue des inondations

Les différents algorithmes d'apprentissages automatique appliqués ont permis d'obtenir la cartographie la plus précise des zones inondées et des zones inondables de la zone d'étude à partir de techniques SAR multi-dates. Les données Sentinel-1 à double polarité (VV/VH) ont été utilisées pour la cartographie des inondations en appliquant l'algorithme CNN et RF et des cartes d'inondation en série chronologique ont été générées à partir de cinq images par mois de la saison humide (6-7 mois). Les meilleurs résultats de la cartographie (issues des classifications CNN) sont présentés dans cette section (*Figure 45*).

Le critère principal pour l'évaluation cartographique des inondations est la distinction des zones inondées des zones non inondées, ce qui peut être traité comme un processus de classification binaire pour étiqueter une région donnée avec "inondation" ou "non inondation".

Dans cette étude, les CNN sont directement utilisés comme classificateurs pour la cartographie des inondations régionales dans le delta du Mékong. L'application de l'algorithme CNN sur les cinq images par mois pendant la saison des pluies permet de délimiter correctement la classe d'inondation sur l'ensemble de la zone inondée.

En comparant l'étendue des inondations, nous constatons que les zones inondées en 2019 sont considérablement plus grandes que les zones inondées en 2020. Ainsi, en 2019, les mois marqués par les périodes de grandes inondations étaient septembre, octobre et novembre, tandis qu'en 2020, il y a un décalage temporaire d'un mois et les mois les plus inondés sont donc octobre, novembre et décembre. Le mois de juillet, qui est un mois de la saison humide, présente la plus faible extension par les zones d'inondation pour les deux années. Les mois de novembre et octobre de la saison humide présentent une extension maximale des zones inondées en 2019 et en 2020 respectivement.

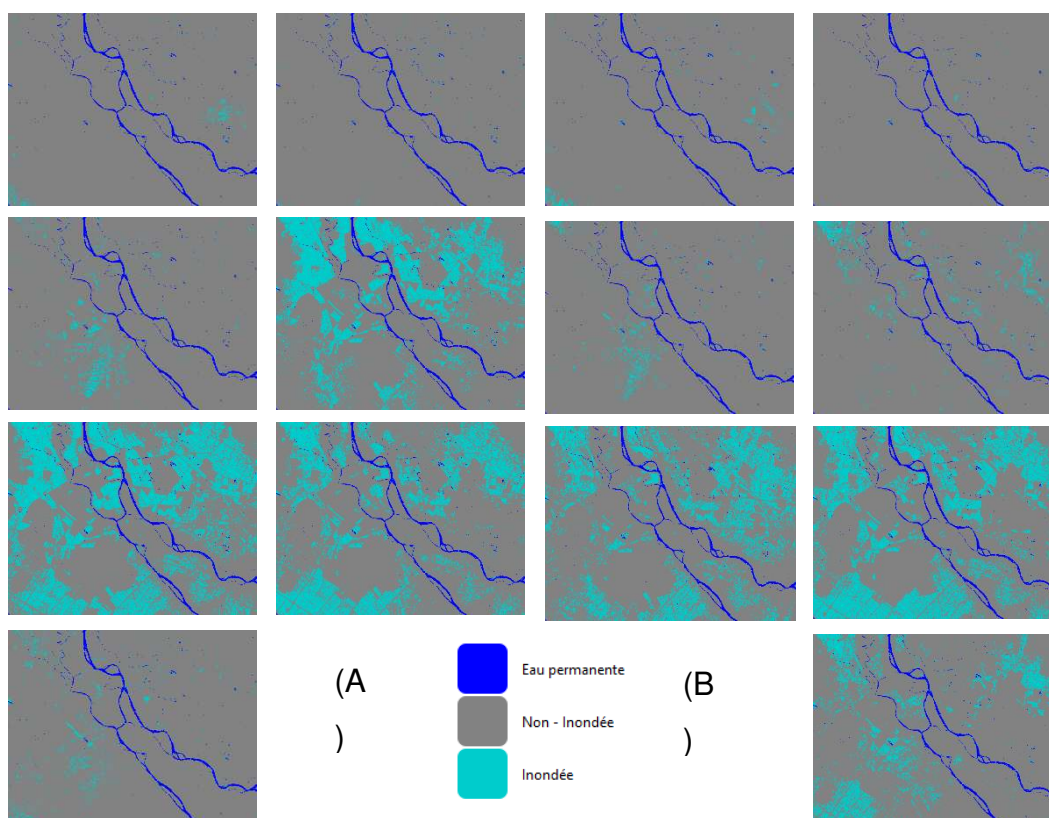


Figure 45 : Cartographie des inondations par classification CNN par mois dans la saison humide de juin à décembre : (A) Zones inondées en 2019 et (B) Zones inondées en 2020

Par ailleurs, nous avons effectué une analyse spatiale basée sur les pixels pour déterminer la surface en Km^2 qui sont correctement délimités avec les cartes résultantes du modèle CNN (Figure 46).

L'étendue maximale des zones inondées (septembre / octobre en 2019 et octobre / novembre en 2020) pour les deux années est en corrélation avec les précipitations moyennes cumulées par mois. L'étendue maximale des zones inondées pour les deux années est répartie sur trois mois (septembre / octobre / novembre en 2019 et octobre / novembre / décembre en 2020). L'étendue maximale des inondations pour les deux années correspond à la troisième saison de culture du riz, ce qui

implique une organisation particulière de la culture du riz pour cette troisième saison (Figure 46).

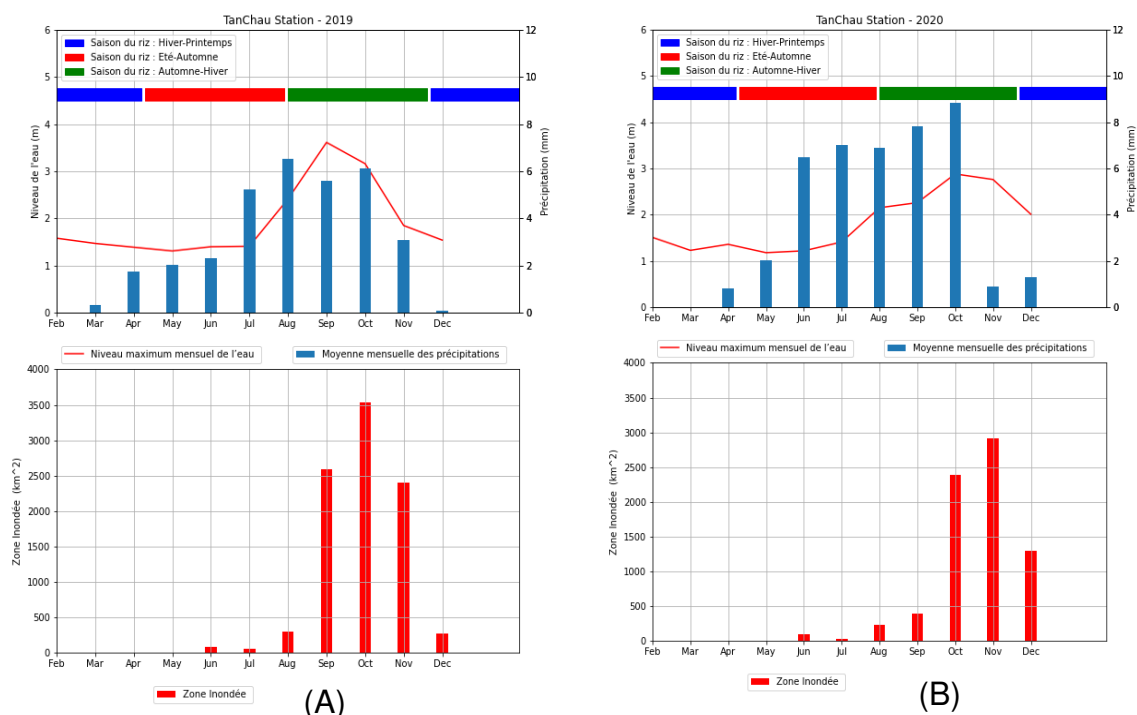


Figure 46 : schéma synthétique a) Précipitations mensuelles moyennes ; niveaux d'eau mensuels maximums en 2019 (A) et 2020 (B) ; b) Zone inondée en km2 pour 2019 (A) et 2020 (B).

Il faut noter que le riz cultivé dans ces régions est un riz profond ou flottant, dont l'eau est fournie par les crues des rivières. Ainsi, les rendements restent faibles car ils sont largement dépendants des conditions climatiques. Avec 8% des surfaces cultivées, ce type de riz ne fournit que 3% de la production mondiale, par conséquent il est progressivement remplacé par le riz irrigué au fur et à mesure des aménagements hydrauliques.

Ainsi, le *tableau 28* présente les résultats de cette analyse spatiale sous forme de pourcentages relatifs au nombre total de pixels.

Tableau 28 : Analyse spatiales des zones impactées par les inondations.

classe	2019		2020	
	Superficie(km ²)	Pourcentage	Superficie(km ²)	Pourcentage
Eau	25.4227	1%	30.0524	1%
Rizière	2615.265	58%	2075.6704	53%
Village	409.666	9%	556.608	14%
Jardin	1208.079	27%	1133.9639	29%
Forêt	220.5616	5%	127.0772	3%
Inondable	4478.9943	100%	3923.3719	100%

A travers l'analyse spatiale (*Tableau 28*), nous constatons que les zones inondées en 2019 (4478,9 km²) sont plus importantes que les zones inondées en 2020

(3923,3 km²). Ces différences dans l'étendue des inondations pourraient indiquer que la crue de 2019 doit être analysée en corrélation avec le niveau maximal du Mékong à la station Tan Chau en 2019 de près de 4 m par rapport au niveau maximal enregistré en 2020 de moins de 3 m à la même station.

9.8.2 Cartographie des zones inondables

Dans cette section l'analyse se concentre, dans un premier temps, sur les classes d'occupation/couverture du sol (LULC) avant la saison humide (*Figure 47b*) pour déterminer quelles classes d'utilisation des terres ont été inondées et, dans un second temps, sur les LULC non inondées (*Figure 47c*). Cette analyse s'est effectuée à partir des informations sur l'extension maximale des zones inondées (partie des zones inondables) pour deux mois, à savoir d'octobre 2019 et de novembre 2020 (*Figure 47a*).

Un des objectifs fixés à travers l'application des deux algorithmes CNN et RF était la mise en évidence de la distribution spatiale des principales classes d'occupation du sol dans la zone d'étude, cette dernière est présentée dans la figure 47b. Ainsi, cinq classes principales, à savoir la rizière, les zones bâties, l'eau, les jardins et les forêts pour les années 2019 et 2020, ont été délimitées. L'étendue surfacique (km²) et la couverture de chaque classe pour les deux périodes d'étude sont présentées dans le *tableau 29*.

Tableau 29 : Superficie de LULC avant la saison des pluies en 2019 et 2020.

classe	2019		2020	
	Superficie(km ²)	Pourcentage	Superficie(km ²)	Pourcentage
Eau	260.3604	2%	318.9245	3%
Rizière	5941.3851	53%	6060.6319	55%
Village	690.8062	6%	426.1447	4%
Jardin	1615.0679	15%	1272.2426	11%
Forêt	2605.3455	24%	3035.0214	27%

L'analyse spatiale de la carte d'occupation du sol montre que la zone bâtie, les rivières / zones humides et les rizières sont plus importantes et plus claires en sorties des classificateurs CNN que RF. On note, ainsi, que les forêts ont tendance à se concentrer dans les zones humides de la zone d'étude.

Durant les deux périodes d'octobre 2019 et de novembre 2020, les rizières occupent plus de la moitié de la zone d'étude (53% en 2019 et 55% en 2020), suivies

par les forêts (24% en 2019 et 27% en 2020) et les jardins avec des superficies, 15% et 11% du paysage, respectivement pour 2019 et 2020. Le pourcentage du couvert urbain était de 6% en 2019 et 4% en 2020, tandis que l'eau représente 2 à 3 % du paysage.

Pour une analyse d'incertitudes de la cartographie à l'aide des techniques SAR, il convient de mentionner que le signal SAR peut être influencé par le chatoiement et donc par une sous-détection ou une sur-détection de l'étendue de l'inondation, en particulier dans les zones urbaines et végétalisées. A cet effet, le modèle CNN vise à réduire les erreurs de classification associées aux hétérogénéités de la couverture terrestre et à la complexité sous-jacente. Même si des erreurs de classification mineures sont observées parmi les classes de couverture du sol, nous pouvons affirmer que le modèle peut séparer efficacement l'eau permanente de l'eau de crue.

Plus de la moitié des rizières ont été inondées durant les deux années (58% en 2019 et 53% en 2020). En 2020, la superficie de rizières est plus importante qu'en 2019, cependant pour cette dernière la superficie des rizières impactée par les inondations était plus grande. Ces inondations ont eu un impact significatif sur une autre classe d'utilisation des terres ayant une valeur économique locale importante. A l'exception des forêts qui ont été moins impactées en 2020, la situation des autres types d'utilisation du sol est plus impactée en 2020 ; on note ainsi que l'urbain a été beaucoup plus touché par l'inondation en 2020 (14%) par rapport à la situation de 2019 (9%), et de même pour les jardins où 29% et 27% de leur superficie est impactée en 2020 et 2019 respectivement.

Le rapport entre chaque classe de LUCU non inondée en 2019 et 2020 et la couverture totale des terres inondables dans l'étude est présenté dans le tableau 10 sous forme de pourcentage.

Les superficies des LULC non-inondées en 2019 et 2020 sont présentées dans le *tableau 30*.

Tableau 30 : Superficie des LULC non inondés en 2019 et 2020

classe	2019		2020	
	Superficie(km ²)	Pourcentage	Superficie(km ²)	Pourcentage
Eau	228.4982	2%	204.5155	2%
Rizière	2554.6812	23%	2866.4995	26%
Village	409.666	4%	556.608	5%
Jardin	1208.079	11%	1522.9639	14%
Forêt	2220.561	20%	2027.0772	18%
Inondable	4478.9943	40%	3923.3719	35%

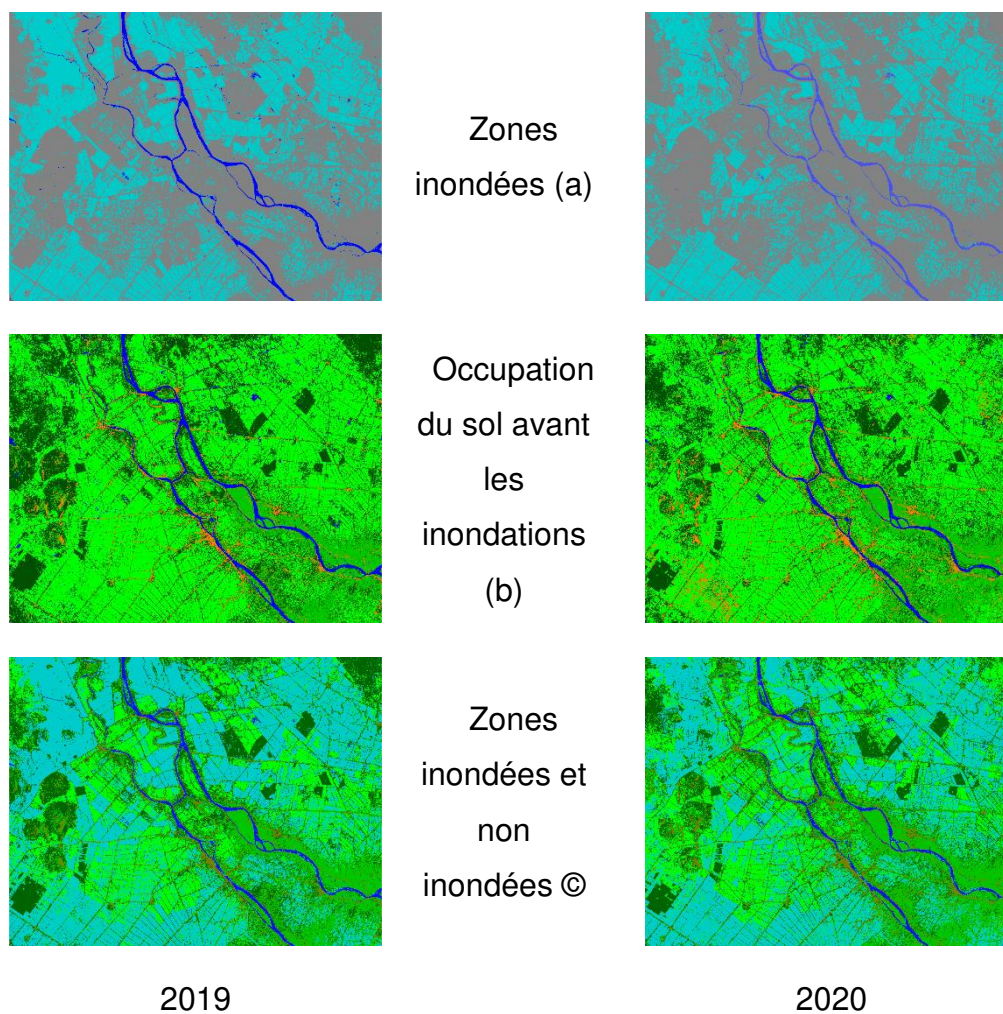


Figure 47 : Cartographie des inondations corrélée avec la cartographie de l'occupation du sol.



9.8.3 Discussion

La modélisation des signatures de classes complexe a été bien considérée par les algorithmes d'apprentissage automatique (Machine Learning), qui peuvent généralement accepter une variété de données prédictives en entrée et ne faire aucune hypothèse sur la distribution des données, c'est-à-dire qu'ils sont non paramétriques (Maxwell et al, 2018).

Les CNN, qui affichent de solides performances en vision par ordinateur et en traitement d'images, sont principalement des réseaux neuronaux multicouches de type feed-forward. Leur objectif principal est d'extraire automatiquement des caractéristiques importantes à partir de données brutes. Les structures CNN de différentes dimensions, en tant que technique puissante, peuvent s'adapter à des données d'entrée de différentes dimensions. Ces aspects peuvent affecter de manière significative les résultats finaux de classification/prédiction.

Dans ce travail, une représentation des données a été introduite pour s'adapter aux nouvelles architectures CNN (CNN-2D, deux couches convolutionnelles, deux couches de mise en commun max et une couche entièrement connectée). Initialement, 120 images sont empilées ensemble pour construire une "image" multicanale, qui est considérée comme une donnée d'entrée pour la transformation ultérieure des données. Dans le domaine de l'évaluation des inondations, l'objectif principal est de proposer une cartographie, qui peut être traitée comme un processus de classification binaire pour étiqueter une zone donnée comme "inondable" ou "non inondable".

Un objectif qui a été atteint dans cette étude où les CNNs sont directement utilisés comme classificateurs pour la détection des inondations régionales. Tout d'abord, une structure CNN a été construite en fonction de la dimensionnalité des données reformées. Après une série d'opérations de convolution et de mise en commun, des cartes de caractéristiques de haut niveau sont extraites des données d'entrée, puis réorganisées par une couche entièrement connectée. Enfin, les vecteurs de caractéristiques réorganisés sont convertis en résultats de classification à l'aide d'une fonction d'activation non linéaire. Pour simplifier, le processus de classification généralisé utilise un classificateur CNN avec l'architecture 2D-CNN.

Nous avons pu ainsi extraire des informations sur les zones inondées et inondables via un traitement au niveau pixel. Il s'agit d'une analyse spatiale surfacique qui a mis en évidence les classes de l'occupation du sol touchée par les inondations durant les années 2019 et 2020, et estimer les étendues et l'extension de cette inondation via une cartographie précise.

Conclusion générale

Le présent travail a comme objectif principal d'étudier en détail les méthodes d'apprentissage automatique supervisé et non supervisé appliquées dans le domaine de l'environnement. C'est une contribution dans l'étude de l'occupation du sol des zones fragiles telles que les systèmes deltaïques. Il s'agit d'un développement méthodologique basé sur l'apport des nouvelles méthodes de télédétection pour le suivi de l'occupation du sol au niveau de deux grands Delta au Vietnam, le delta du fleuve Rouge et le delta du Mékong. Ainsi, la thèse a permis de mettre en évidence les progrès qui ont été réalisés dans l'utilisation de données satellitaires de haute résolution spatiale, ainsi que des méthodes de l'Intelligence Artificielle (Machine et Deep Learning).

Pour aboutir à nos objectifs nous avons utilisé des données multi-capteurs et des séries temporelles. Une modélisation de l'organisation des données satellites optiques et radar a été effectuée afin d'améliorer les résultats d'analyse d'images. Ces données ont été utilisées pour deux sortes d'application, la cartographie du type de végétation et le suivi de l'extension de l'inondation et des zones inondables. En effet, par rapport à des études d'analyse d'images uniques, les données optiques de séries temporelles et les méthodes de traitement ici développées ont démontré leur efficacité et faisabilité dans le processus de cartographie de la végétation du delta du fleuve Rouge. Par ailleurs, les séries temporelles des données SAR se sont avérées efficaces pour surveiller et cartographier les zones inondables au niveau du delta du Mékong. Pour cette dernière application une approche systémique regroupant les données environnementales et météorologiques ainsi que des données de télédétection a permis d'étudier les zones inondables et de cartographier l'extension de l'inondation. Cette approche met en avant la contribution des données satellites et les technologies de télédétection; et aide à tracer les plans de prévention du risque et orienter les politiques de gestion spatiales des zones deltaïques.

Par ailleurs, les méthodes d'apprentissage non supervisées ont été appliquées pour effectuer des segmentations et extraire des objets géographiques d'images satellitaires. Des algorithmes de segmentation ont été étudiés et appliqués lors du développement méthodique afin d'identifier le meilleur choix pour notre domaine d'application. Ces algorithmes ont été vérifiés et validés via une approche comparative et à travers plusieurs essais.

Ainsi, nous avons constaté que le choix de la méthode de segmentation affecte grandement les résultats de l'analyse d'images. Chaque méthode de segmentation est optimisée et adaptée aux données en ajustant ces paramètres. Grâce à l'évaluation et à la comparaison des résultats, la méthode de segmentation multi-résolution (*Mutiresolution Segmentation*) a été choisie pour être utilisée pour le processus de classification. Ce choix repose sur des mesures de similarité qui comprennent la mesure de similarité spectrales et des couleurs ainsi que sur des coefficients de rétrodiffusion et la mesure de similarité de la forme et la taille de chaque objet géographique.

En outre, les méthodes d'apprentissage supervisé, y compris les méthodes d'apprentissage peu profond et profond, ont été étudiées et testées, il s'agit de Support Vector Machine (SVM), Random Forest (RF), Multi-Layer Perceptron (MLP), et Convolutional Neural Network (CNN). Les comparaisons d'efficacité entre les méthodes de classification d'images ont été réalisées. Les expérimentations ont fourni des options pour estimer les valeurs des paramètres de chaque algorithme et d'optimiser l'efficacité des algorithmes pour chaque cas de données utilisé dans l'analyse. Ainsi, nous avons appliqué des méthodes d'évaluation pour estimer la pertinence des résultats issus des classifications d'images et de la cartographie extraite par le processus de GEOBIA.

La contribution de la méthode d'analyse orientée objet (GEOBIA) est considérée comme importante et efficace pour des applications de surveillance de l'occupation du sol au niveau des systèmes des deltas du Vietnam. Le processus d'application est adapté par une optimisation et configuration rigoureuse des paramètres pour chaque étape : prétraitement des données satellites optiques et radars, segmentation et extraction des objets géographiques, classification des objets géographiques, et enfin le processus d'évaluation des résultats de la classification.

Selon la tendance de développement des méthodes d'apprentissage profond et leurs résultats, nous constatons que le CNN pourrait être adapté pour contribuer dans de nombreuses futures applications et d'analyse des données. Dans le cadre de la thèse, le CNN est utilisé comme une méthode de classification de GEOBIA, la méthode de segmentation utilisée est la méthode manuelle physique (découper des images par une petite fenêtre), en plus de certaines recherches d'analyse d'images, CNN est utilisé pour l'extraction de carte des caractéristiques d'images. Ainsi, nous proposons de continuer à étudier l'application de CNN dans le prétraitement des données afin d'en extraire des caractéristiques utiles et d'améliorer les résultats d'interprétation

d'images. A partir de là, il est possible de construire un modèle GEOBIA avec le changement de l'étape de prétraitement des données pour utiliser plus efficacement les applications de la méthode d'apprentissage profond de CNN.

De plus, il est nécessaire de réaliser des expérimentations combinant des séries temporelles de données optiques et radar pour étudier les phénomènes de croissance des végétations ou l'évolution des risques climatiques sur une plus longue période dans les deltas et les zones côtières du Vietnam. Les phénomènes de l'inondation, la sécheresse et l'intrusion saline dans les zones côtières ont provoqué un changement de l'occupation du sol dans les systèmes deltaïques du Vietnam. Ainsi, sans un contrôle et suivi efficaces, ces changements pourraient avoir un impact dévastateur sur l'équilibre naturel et socio-économique du pays vu l'importance de la région.

Bibliographie

- Abdikan, S., Balik Sanli, F., Üstüner, M., Calò, F., 2016. LAND COVER MAPPING USING SENTINEL-1 SAR DATA, ISPRS - International Archives of the Photogrammetry, Remote Sensing et Spatial Information Sciences. <https://doi.org/10.5194/isprs-archives-XLI-B7-757-2016>
- Achanta, R., Shaji, A., Smith, K., Lucchi, A., Fua, P., Süsstrunk, S., 2010. SLIC superpixels. Technical report, EPFL.
- A.Gibril, M., Shafri, H., Hamedianfar, A., 2017. New semi-automated mapping of asbestos cement roofs using rule-based object-based image analysis et Taguchi optimization technique from WorldView-2 images. *International Journal of Remote Sensing* 38, 467–491. <https://doi.org/10.1080/01431161.2016.1266109>
- Arisoy, S., Kayabol, K., 2016. Mixture-Based Superpixel Segmentation et Classification of SAR Images. *IEEE Geoscience et Remote Sensing Letters* 13, 1721–1725. <https://doi.org/10.1109/LGRS.2016.2605583>
- Awad, M., Khanna, R., 2015. Machine Learning, in: Awad, M., Khanna, R. (Eds.), *Efficient Learning Machines: Theories, Concepts, et Applications for Engineers et System Designers*. Apress, Berkeley, CA, pp. 1–18. https://doi.org/10.1007/978-1-4302-5990-9_1
- Baatz, M., Hoffmann, C., Willhauck, G., 2008. Progressing from object-based to object-oriented image analysis, in: Blaschke, T., Lang, S., Hay, G.J. (Eds.), *Object-Based Image Analysis: Spatial Concepts for Knowledge-Driven Remote Sensing Applications*, *Lecture Notes in Geoinformation et Cartography*. Springer, Berlin, Heidelberg, pp. 29–42. https://doi.org/10.1007/978-3-540-77058-9_2
- Baatz, M., Schape, A., 2000. Multiresolution segmentation: an optimization approach for high quality multi-scale image segmentation. *Multiresolution Segmentation: An Optimization Approach for High Quality Multi-scale Image Segmentation* 12–23.
- Balzter, H., Cole, B., Thiel, C., Schmillius, C., 2015. Mapping CORINE Land Cover from Sentinel-1A SAR et SRTM Digital Elevation Model Data using *Random Forests*. *Remote Sensing* 7, 14876–14898. <https://doi.org/10.3390/rs71114876>
- Bé, N., Van, T., Hằng, T., Ân, N., 2017. Ảnh hưởng của xâm nhập mặn đến công tác quản lý nguồn tài nguyên nước trong sản xuất nông nghiệp tại huyện Long Phú, tỉnh Sóc Trăng. *Can Tho University, Journal of Science* 52, 104. <https://doi.org/10.22144/ctu.jvn.2017.116>

- Bengio, Y., Courville, A., Vincent, P., 2014. Representation Learning: A Review et New Perspectives. arXiv:1206.5538 [cs].
- Benz, U.C., Hofmann, P., Willhauck, G., Lingenfelder, I., Heynen, M., 2004. Multi-resolution, object-oriented fuzzy analysis of remote sensing data for GIS-ready information. *ISPRS Journal of Photogrammetry et Remote Sensing, Integration of Geodata et Imagery for Automated Refinement et Update of Spatial Databases* 58, 239–258. <https://doi.org/10.1016/j.isprsjprs.2003.10.002>
- Bergeret, P., 2004. Les enjeux de la libéralisation économique pour le développement agricole au Vietnam, Dans *Le Vietnam à l’aube du XXIe siècle: Bilan et perspectives politiques, économiques et sociales*, Karthala. ed.
- Bianchi, T., Allison, M., 2009. Large-river delta-front estuaries as natural “recorders” of global environmental change. *Proceedings of the National Academy of Sciences*. <https://doi.org/10.1073/pnas.0812878106>
- Biggs, D.A., 2012. *Quagmire: Nation-Building et Nature in the Mekong Delta*. University of Washington Press.
- Blaschke, T., 2010. Object based image analysis for remote sensing. *ISPRS Journal of Photogrammetry et Remote Sensing* 65, 2–16. <https://doi.org/10.1016/j.isprsjprs.2009.06.004>
- Blaschke, T., Hay, G.J., Kelly, M., Lang, S., Hofmann, P., Addink, E., Queiroz Feitosa, R., van der Meer, F., van der Werff, H., van Coillie, F., Tiede, D., 2014. Geographic Object-Based Image Analysis - Towards a new paradigm. *ISPRS Journal of Photogrammetry et Remote Sensing* 87, 180–191. <https://doi.org/10.1016/j.isprsjprs.2013.09.014>
- Boualleg, Y., Farah, M., Farah, I.R., 2019. Remote Sensing Scene Classification Using Convolutional Features et Deep Forest Classifier. *IEEE Geoscience et Remote Sensing Letters* 16, 1944–1948. <https://doi.org/10.1109/LGRS.2019.2911855>
- Bovenga, F., 2020. Special Issue “Synthetic Aperture Radar (SAR) Techniques et Applications.” *Sensors (Basel)* 20, 1851. <https://doi.org/10.3390/s20071851>
- Breiman, L. (Ed.), 1998. *Classification et regression trees*, 1. CRC Press repr. ed. Chapman & Hall/CRC, Boca Raton, Fla.
- Breiman, L., 1996. Bagging predictors. *Mach Learn* 24, 123–140. <https://doi.org/10.1007/BF00058655>
- Breiman, L., 2001. *Random Forests*. *Machine Learning* 45, 5–32. <https://doi.org/10.1023/A:1010933404324>
- Brown, P.R., Tuan, V.V., Nhan, D.K., Dung, L.C., Ward, J., 2018. Influence of livelihoods on climate change adaptation for smallholder farmers in the

Mekong Delta Vietnam. null 16, 255–271.
<https://doi.org/10.1080/14735903.2018.1472858>

Ca, V.T., Vongvisessomjai, S., Asaeda, T., 1994. Study on Salinity Intrusion in the Red River Delta. *Environmental Systems Research* 22, 213–218.
<https://doi.org/10.2208/proer1988.22.213>

Carreira-Perpiñán, M.Á., 2015. A review of mean-shift algorithms for clustering. arXiv:1503.00687 [cs, stat].

Catlett, J., 1991. *Megainduction: Machine Learning on Very Large Databases*. University of Sydney.

Castilla, G., Hay, G. J., 2008. Image objects et geographic objects, in: Blaschke, T., Lang, S., Hay, Geoffrey J. (Eds.), *Object-Based Image Analysis: Spatial Concepts for Knowledge-Driven Remote Sensing Applications*, Lecture Notes in Geoinformation et Cartography. Springer, Berlin, Heidelberg, pp. 91–110.
https://doi.org/10.1007/978-3-540-77058-9_5

Cian, F., Marconcini, M., Ceccato, P., 2018. Normalized Difference Flood Index for rapid flood mapping: Taking advantage of EO big data. *Remote Sensing of Environment* 209, 712–730. <https://doi.org/10.1016/j.rse.2018.03.006>

Cloude, S., Zebker, H., 2010. Polarisation: Applications in Remote Sensing. *Physics Today - PHYS TODAY* 63. <https://doi.org/10.1063/1.3502550>

Cochran, W.G., 1977. *Sampling Techniques*, 3rd Edition. John Wiley.

Comaniciu, D., Ramesh, V., Meer, P., 2001. The variable bandwidth mean shift et data-driven scale selection, in: *Proceedings Eighth IEEE International Conference on Computer Vision. ICCV 2001*. Presented at the *Proceedings Eighth IEEE International Conference on Computer Vision. ICCV 2001*, pp. 438–445 vol.1. <https://doi.org/10.1109/ICCV.2001.937550>

Congalton, R., Green, K., 2019. *Assessing the Accuracy of Remotely Sensed Data: Principles et Practices*, Third Edition. <https://doi.org/10.1201/9780429052729>

Cortes, C., Vapnik, V., 1995. Support-vector networks. *Mach Learn* 20, 273–297.
<https://doi.org/10.1007/BF00994018>

Cosslett, T.L., Cosslett, P.D., 2014. Major Threats to Mekong Delta: Climate Change et Mainstream Dams, in: Cosslett, T.L., Cosslett, P.D. (Eds.), *Water Resources et Food Security in the Vietnam Mekong Delta*, Natural Resource Management et Policy. Springer International Publishing, Cham, pp. 75–96.
https://doi.org/10.1007/978-3-319-02198-0_3

Dai, Q., Wang, L., Xu, Q., Zhang, Y., 2014. An mean shift algorithm with adaptive bandwidth et weight selection for high spatial remotely sensed imagery segmentation, in: *2014 IEEE Geoscience et Remote Sensing Symposium*.

Presented at the 2014 IEEE Geoscience et Remote Sensing Symposium, pp. 1592–1595. <https://doi.org/10.1109/IGARSS.2014.6945950>

- Dang, T.H., Coynel, A., Orange, D., Blanc, G., Etcheber, H., Le, L.A., 2010. Long-term monitoring (1960–2008) of the river-sediment transport in the Red River Watershed (Vietnam): Temporal variability et dam-reservoir impact. *Science of The Total Environment* 408, 4654–4664. <https://doi.org/10.1016/j.scitotenv.2010.07.007>
- Đạt T.Q., Trung N.H., Likitdecharote K., 2012. MÔ PHỎNG XÂM NHẬP MẶN ĐỒNG BẰNG SÔNG CỬU LONG DƯỚI TÁC ĐỘNG MỰC NƯỚC BIỂN DÂNG VÀ SỰ SUY GIẢM LƯU LƯỢNG TỪ THƯỢNG NGUỒN. *Tạp chí Khoa học Trường Đại học Cần Thơ Số 21b*, 141–150.
- Delgado, J.M., Apel, H., Merz, B., 2010. Flood trends et variability in the Mekong river. *Hydrology et Earth System Sciences* 14, 407–418. <https://doi.org/10.5194/hess-14-407-2010>
- Demirović, D., 2019. An Implementation of the Mean Shift Algorithm. *Image Processing On Line* 9, 251–268. <https://doi.org/10.5201/ipol.2019.255>
- Dhara, S., Dang, T., Parial, K., Lu, X.X., 2020. Accounting for Uncertainty et Reconstruction of Flooding Patterns Based on Multi-Satellite Imagery et Support Vector Machine Technique: A Case Study of Can Tho City, Vietnam. *Water* 12, 1543. <https://doi.org/10.3390/w12061543>
- Do, N.H., Egashira, K., 2002. Irrigation et drainage systems et their impact on land use et rice production after renovation (Doi Moi) in the Red River delta of Vietnam - A case study in Tien Son District, Bac Ninh Province. *Journal- Faculty of Agriculture Kyushu University* 46, 411–422.
- Dobrinić, D., Gašparović, M., Medak, D., 2021. Sentinel-1 et 2 Time-Series for Vegetation Mapping Using *Random Forest* Classification: A Case Study of Northern Croatia. *Remote Sensing* 13, 2321. <https://doi.org/10.3390/rs13122321>
- Dobrinić, D., Medak, D., Gašparović, M., 2020. INTEGRATION OF MULTITEMPORAL SENTINEL-1 AND SENTINEL-2 IMAGERY FOR LAND-COVER CLASSIFICATION USING MACHINE LEARNING METHODS, in: *The International Archives of the Photogrammetry, Remote Sensing et Spatial Information Sciences. Presented at the XXIV ISPRS Congress, Commission I (Volume XLIII-B1-2020) - 2020 edition*, Copernicus GmbH, pp. 91–98. <https://doi.org/10.5194/isprs-archives-XLIII-B1-2020-91-2020>
- Dorian, B., 2015. L'utilisation de l'agent orange durant la guerre du Vietnam et ses conséquences sur la santé.
- Drăguț, L., Tiede, D., Levick, S.R., 2010. ESP: a tool to estimate scale parameter for multiresolution image segmentation of remotely sensed data. *International*

- Dumanski, J., Pieri, C., 2000. Land quality indicators: research plan. *Agriculture, Ecosystems & Environment* 81, 93–102. [https://doi.org/10.1016/S0167-8809\(00\)00183-3](https://doi.org/10.1016/S0167-8809(00)00183-3)
- Fang, G., Kwok, Y.-K., Yu, K., Zhu, Y., 1999. Numerical simulation of principal tidal constituents in the South China Sea, Gulf of Tonkin et Gulf of Thailand. *Continental Shelf Research* 19, 845–869. [https://doi.org/10.1016/S0278-4343\(99\)00002-3](https://doi.org/10.1016/S0278-4343(99)00002-3)
- FAO, 2016. *FAO Yearbook. Fishery et Aquaculture Statistics 2014. FAO annuaire. Statistiques des pêches et de l'aquaculture 2014. FAO anuario. Estadísticas de pesca y acuicultura 2014, FAO Yearbook of Fishery et Aquaculture Statistics.* FAO, Rome, Italy.
- Filipponi, F., 2019. Sentinel-1 GRD Preprocessing Workflow. *Proceedings* 18, 11. <https://doi.org/10.3390/ECRS-3-06201>
- Foley, J., Defries, R., Asner, G., Barford, C., Bonan, G., Carpenter, S., Chapin III, F.S., Coe, M., Daily, G., Gibbs, H., Helkowski, J., Holloway, T., Howard, E., Kucharik, C., Monfreda, C., Patz, J., Prentice, I., Ramankutty, N., Snyder, P., 2005. Global Consequences of Land Use. *Science (New York, N.Y.)* 309, 570–4. <https://doi.org/10.1126/science.1111772>
- Foley, J.A., DeFries, R., Asner, G.P., Barford, C., Bonan, G., Carpenter, S.R., Chapin, F.S., Coe, M.T., Daily, G.C., Gibbs, H.K., Helkowski, J.H., Holloway, T., Howard, E.A., Kucharik, C.J., Monfreda, C., Patz, J.A., Prentice, I.C., Ramankutty, N., Snyder, P.K., 2005. Global Consequences of Land Use. *Science* 309, 570–574. <https://doi.org/10.1126/science.1111772>
- Foody, G.M., Mathur, A., 2004. Toward intelligent training of supervised image classifications: directing training data acquisition for SVM classification. *Remote Sensing of Environment* 93, 107–117. <https://doi.org/10.1016/j.rse.2004.06.017>
- Fourie, C., Schoepfer, E., 2014. Data Transformation Functions for Expanded Search Spaces in Geographic Sample Supervised Segment Generation. *Remote Sensing* 6, 3791–3821. <https://doi.org/10.3390/rs6053791>
- Frenken, K., 2012. Mekong River Basin.” In *Irrigation in Southern et Eastern Asia in Figures: Aquastat Survey.* FAO Water Reports.
- Fu, T., Ma, L., Li, M., Johnson, B.A., 2018. Using convolutional neural network to identify irregular segmentation objects from very high-resolution remote sensing imagery. *JARS* 12, 025010. <https://doi.org/10.1117/1.JRS.12.025010>

- Fukunaga, K., Hostetler, L., 1975. The estimation of the gradient of a density function, with applications in pattern recognition. *IEEE Transactions on Information Theory* 21, 32–40. <https://doi.org/10.1109/TIT.1975.1055330>
- Gao, Y., Mas, J., Kerle, N., Pacheco, J., 2011. Optimal region growing segmentation et its effect on classification accuracy. *International Journal of Remote Sensing* 32, 3747–3763. <https://doi.org/10.1080/01431161003777189>
- Gilard, O., 2006. Risques d'inondation dans le delta du fleuve Rouge. *Herodote* no 121, 42–54.
- Gislason, P.O., Benediktsson, J.A., Sveinsson, J.R., 2006. *Random Forests* for land cover classification. *Pattern Recognition Letters, Pattern Recognition in Remote Sensing (PRRS 2004)* 27, 294–300. <https://doi.org/10.1016/j.patrec.2005.08.011>
- Gong, P., Wang, J., Yu, Le, Zhao, Yongchao, Zhao, Yuanyuan, Liang, L., Niu, Z., Huang, X., Fu, H., Liu, S., Li, C., Li, X., Fu, W., Liu, C., Xu, Y., Wang, X., Cheng, Q., Hu, L., Yao, W., Zhang, Han, Zhu, P., Zhao, Z., Zhang, Haiying, Zheng, Y., Ji, L., Zhang, Y., Chen, H., Yan, A., Guo, J., Yu, Liang, Wang, L., Liu, X., Shi, T., Zhu, M., Chen, Y., Yang, G., Tang, P., Xu, B., Giri, C., Clinton, N., Zhu, Z., Chen, Jin, Chen, Jun, 2013. Finer resolution observation et monitoring of global land cover: first mapping results with Landsat TM et ETM+ data. *International Journal of Remote Sensing* 34, 2607–2654. <https://doi.org/10.1080/01431161.2012.748992>
- Gu, H., Li, H., Yan, L., Lu, X., 2015. A Framework for Geographic Object-Based Image Analysis (GEOBIA) based on geographic ontology. *ISPRS - International Archives of the Photogrammetry, Remote Sensing et Spatial Information Sciences XL-7/W4*, 27–33. <https://doi.org/10.5194/isprsarchives-XL-7-W4-27-2015>
- Gupta, A., 2009. Chapter 3 - Geology et Landforms of the Mekong Basin, in: Campbell, I.C. (Ed.), *The Mekong, Aquatic Ecology*. Academic Press, San Diego, pp. 29–51. <https://doi.org/10.1016/B978-0-12-374026-7.00003-6>
- Ha, T.T.P., van Dijk, H., Visser, L., 2014. Impacts of changes in mangrove forest management practices on forest accessibility et livelihood: A case study in mangrove-shrimp farming system in Ca Mau Province, Mekong Delta, Vietnam. *Land Use Policy* 36, 89–101. <https://doi.org/10.1016/j.landusepol.2013.07.002>
- Hall, J., Arheimer, B., Borga, M., Brázdil, R., Claps, P., Kiss, A., Kjeldsen, T.R., Kriaučiūnienė, J., Kundzewicz, Z.W., Lang, M., Llasat, M.C., Macdonald, N., McIntyre, N., Mediero, L., Merz, B., Merz, R., Molnar, P., Montanari, A., Neuhold, C., Parajka, J., Perdigão, R. a. P., Plavcová, L., Rogger, M., Salinas, J.L., Sauquet, E., Schär, C., Szolgay, J., Viglione, A., Blöschl, G., 2014. Understanding flood regime changes in Europe: a state-of-the-art assessment.

- Hamada, M.A., Kanat, Y., Abiche, A.E., 2019. Multi-Spectral Image Segmentation Based on the K-means Clustering 9, 4.
- Haruyama, S., 1995. Geomorphologic features of the Song Hong delta. *J Int Relat Stud* 21, 1–13.
- Hashimoto, T.R., 2001. Environmental Issues et Recent Infrastructure Development in the Mekong Delta: Review, Analysis et Recommendations with Particular Reference to Large-Scale Wa-ter Control Projects et the Development of Coastal Areas, (Working Paper No. 4). Australian Mekong Resource Centre, University of Sydney, Australia.
- Hay, G., Castilla, G., 2008. Geographic Object-Based Image Analysis (GEOBIA): A new name for a new discipline, in: *Object-Based Image Analysis - Spatial Concepts for Knowledge-Driven Remote Sensing Applications*. pp. 75–89. https://doi.org/10.1007/978-3-540-77058-9_4
- Hay, G.J., 1994. Visualizing 3-D texture: a three dimensional structural approach to model forest texture. *Can. J. Remote Sensing* 90–101.
- Hay, G.J., Niemann, K.O., McLean, G.F., 1996. An object-specific image-texture analysis of H-resolution forest imagery. *Remote Sensing of Environment* 55, 108–122. [https://doi.org/10.1016/0034-4257\(95\)00189-1](https://doi.org/10.1016/0034-4257(95)00189-1)
- Hay, G.J., Niernann, K.O., Goodenough, D.G., 1997. Spatial thresholds, image-objects, et upscaling: A multiscale evaluation. *Remote Sensing of Environment* 62, 1–19. [https://doi.org/10.1016/S0034-4257\(97\)81622-7](https://doi.org/10.1016/S0034-4257(97)81622-7)
- Hinton, G.E., Osindero, S., Teh, Y.-W., 2006. A Fast Learning Algorithm for Deep Belief Nets. *Neural Computation* 18, 1527–1554. <https://doi.org/10.1162/neco.2006.18.7.1527>
- Hirabayashi, Y., Mahendran, R., Koirala, S., Konoshima, L., Yamazaki, D., Watanabe, S., Kim, H., Kanae, S., 2013. Global flood risk under climate change. *Nature Climate Change* 3, 816–821. <https://doi.org/10.1038/nclimate1911>
- Hoanh, C.T., , N.D. Phong, T.P. Tuong, J.W. Gowing, N.V. Ngoc, L.T. An, et N.V. MinhPhong, T.P. Tuong, J.W. Gowing, N.V. Ngoc, L.T. An., Minh, et N.V., 2002. Water Management For Sustainable Agricultural And Aquacultural Development In Bac Lieu Province. Paper presented at the Mid-term Review IRRI, University of Newcastle, ICLARM, University of Can Tho, Sub-Institute of Water Resources Planning, Department of Agriculture & Rural Development, Bac Lieu Province, Vietnam. Presented at the Workshop in Bac Lieu June 2002.

- Hong Quang, N., Tuan, V.A., Thi Thu Hang, L., Manh Hung, N., Thi The, D., Thi Dieu, D., Duc Anh, N., Hackney, C.R., 2020. Hydrological/Hydraulic Modeling-Based Thresholding of Multi SAR Remote Sensing Data for Flood Monitoring in Regions of the Vietnamese Lower Mekong River Basin. *Water* 12, 71. <https://doi.org/10.3390/w12010071>
- Huang, C., Davis, L., Townshend, J., 2002. An assessment of support vector machines for land cover classification. *International Journal of Remote Sensing* 23. <https://doi.org/10.1080/01431160110040323>
- Hung, B.V., 2017. Identify the Major Reasons to Cause Vulnerability to Mekong Delta Under the Impacts of Drought et Climate Change, in: Kurisu, F., Ramanathan, AL., Kazmi, A.A., Kumar, M. (Eds.), *Trends in Asian Water Environmental Science et Technology*. Springer International Publishing, Cham, pp. 211–222. https://doi.org/10.1007/978-3-319-39259-2_18
- IMHEN, 2011. Scenarios of climate change et sea level rises for Viet Nam. Ministry of Natural Resources et Environments, Hanoi.
- Ienco, D., Interdonato, R., Gaetano, R., Ho Tong Minh, D., 2019. Combining Sentinel-1 et Sentinel-2 Satellite Image Time Series for land cover mapping via a multi-source deep learning architecture. *ISPRS Journal of Photogrammetry et Remote Sensing* 158, 11–22. <https://doi.org/10.1016/j.isprsjprs.2019.09.016>
- Jozdani, S., Johnson, B., Chen, D., 2019. Comparing Deep Neural Networks, Ensemble Classifiers, et Support Vector Machine Algorithms for Object-Based Urban Land Use/Land Cover Classification. *Remote Sensing* 11. <https://doi.org/10.3390/rs11141713>
- Kansakar, P., Hossain, F., 2016. A review of applications of satellite earth observation data for global societal benefit et stewardship of planet earth. *Space Policy* 36, 46–54. <https://doi.org/10.1016/j.spacepol.2016.05.005>
- Kavitha, A.V., Srikrishna, A., Satyanarayana, C., 2021. A Review on Detection of Land Use et Land Cover from an Optical Remote Sensing Image. *IOP Conf. Ser.: Mater. Sci. Eng.* 1074, 012002. <https://doi.org/10.1088/1757-899X/1074/1/012002>
- Kettig, R.L., Landgrebe, D.A., 1976. Classification of Multispectral Image Data by Extraction et Classification of Homogeneous Objects. *IEEE Transactions on Geoscience Electronics* 14, 19–26. <https://doi.org/10.1109/TGE.1976.294460>
- Khan, S.S., Ahmad, A., 2004. Cluster center initialization algorithm for K-means clustering. *Pattern Recognition Letters* 25, 1293–1302. <https://doi.org/10.1016/j.patrec.2004.04.007>
- Kondolf, G.M., Rubin, Z.K., Minear, J.T., 2014. Dams on the Mekong: Cumulative sediment starvation. *Water Resources Research* 50, 5158–5169. <https://doi.org/10.1002/2013WR014651>

- Kontgis, C., Schneider, A., Ozdogan, M., 2015. Mapping rice paddy extent et intensification in the Viêt-Nameese Mekong River Delta with dense time stacks of Landsat data. *Remote Sensing of Environment* 169, 255–269. <https://doi.org/10.1016/j.rse.2015.08.004>
- Kuemmerle, T., Chaskovskyy, O., Knorn, J., Radeloff, V.C., Kruhlov, I., Keeton, W.S., Hostert, P., 2009. Forest cover change et illegal logging in the Ukrainian Carpathians in the transition period from 1988 to 2007. *Remote Sensing of Environment* 113, 1194–1207. <https://doi.org/10.1016/j.rse.2009.02.006>
- Lambin, E.F., Geist, H., n.d. *Land-use et Land-cover Change: Local Processes et Global Impacts*. Springer London NetLibrary, Inc. [distributor], Guildford Boulder.
- Lambin, E.F., Geist, H.J., 2006. *Land-Use et Land-Cover Change: Local Processes et Global Impacts*. Springer Science & Business Media.
- Lam-Dao, N., Pham-Bach, V., Nguyen-Thanh, M., Pham-Thi, M.-T., Hoang-Phi, P., 2011. Change Detection of Land use et Riverbank in Mekong Delta, Vietnam using Time Series Remotely Sensed Data. *Jore* 2, 370–374. <https://doi.org/10.3969/j.issn.1674-764x.2011.04.011>
- Lary, D.J., Alavi, A.H., Gandomi, A.H., Walker, A.L., 2016. Machine learning in geosciences et remote sensing. *Geoscience Frontiers, Special Issue: Progress of Machine Learning in Geosciences* 7, 3–10. <https://doi.org/10.1016/j.gsf.2015.07.003>
- Le, T.P.Q., Garnier, J., Gilles, B., Sylvain, T., Van Minh, C., 2007. The changing flow regime et sediment load of the Red River, Viet Nam. *Journal of Hydrology* 334, 199–214. <https://doi.org/10.1016/j.jhydrol.2006.10.020>
- LeCun, Y., Bengio, Y., Hinton, G., 2015. Deep Learning. *Nature* 521, 436–44. <https://doi.org/10.1038/nature14539>
- Lee, J., Jurkevich, L., Dewaele, P., Wambacq, P., Oosterlinck, A., 1994a. Speckle filtering of synthetic aperture radar images: A Review. *Remote Sensing Reviews* 8. <https://doi.org/10.1080/02757259409532206>
- Lee, J., Jurkevich, L., Dewaele, P., Wambacq, P., Oosterlinck, A., 1994b. Speckle filtering of synthetic aperture radar images: A Review. *Remote Sensing Reviews* 8. <https://doi.org/10.1080/02757259409532206>
- Lee, J.S., Pottier, E., 2009. *Polarimetric Radar Imaging : From basics to applications., Optical Science et Engineering*. CRC Press, Taylor & Francis Editor,.
- Lewis, D.D., Catlett, J., 1994. Heterogeneous Uncertainty Sampling for Supervised Learning, in: *In Proceedings of the Eleventh International Conference on Machine Learning*. Morgan Kaufmann, pp. 148–156.

- Li, Z., Saito, Y., Matsumoto, E., Wang, Y., Tanabe, S., Lan Vu, Q., 2006. Climate change et human impact on the Song Hong (Red River) Delta, Vietnam, during the Holocene. *Quaternary International*, Precipitation: it's influence on Quaternary events in eastern Asia 144, 4–28. <https://doi.org/10.1016/j.quaint.2005.05.008>
- Liu, D., Xia, F., 2010. Assessing object-based classification: Advantages et limitations. *Remote Sensing Letters* 1, 187–194. <https://doi.org/10.1080/01431161003743173>
- Liu, S., Li, X., Chen, D., Duan, Y., Ji, H., Zhang, L., Chai, Q., Hu, X., 2020. Understanding Land use/Land cover dynamics et impacts of human activities in the Mekong Delta over the last 40 years. *Global Ecology et Conservation* 22, e00991. <https://doi.org/10.1016/j.gecco.2020.e00991>
- Longepe, N., Rakwatin, P., Isoguchi, O., Shimada, M., Uryu, Y., Yulianto, K., 2011. Assessment of ALOS PALSAR 50 m Orthorectified FBD Data for Regional Land Cover Classification by Support Vector Machines. *IEEE Transactions on Geoscience et Remote Sensing* 49, 2135–2150. <https://doi.org/10.1109/TGRS.2010.2102041>
- Lowe, B., Kulkarni, A., 2015. Multispectral Image Analysis Using *Random Forest*. *International Journal on Soft Computing* 6, 1–14. <https://doi.org/10.5121/ijsc.2015.6101>
- Luu, T.N.M., Garnier, J., Billen, G., Orange, D., Némery, J., Le, T.P.Q., Tran, H.T., Le, L.A., 2010. Hydrological regime et water budget of the Red River Delta (Northern Vietnam). *Journal of Asian Earth Sciences* 37, 219–228. <https://doi.org/10.1016/j.jseaes.2009.08.004>
- Lv, X., Ming, D., Chen, Y., Wang, M., 2018. Very high resolution remote sensing image classification with SEEDS-CNN et scale effect analysis for superpixel CNN classification. *International Journal of Remote Sensing* 40, 1–26. <https://doi.org/10.1080/01431161.2018.1513666>
- Ma, L., Du, B., Chen, H., Soomro, N.Q., 2016. Region-of-Interest Detection via Superpixel-to-Pixel Saliency Analysis for Remote Sensing Image. *IEEE Geoscience et Remote Sensing Letters* 13, 1752–1756. <https://doi.org/10.1109/LGRS.2016.2602885>
- Ma, L., Li, M., Ma, X., Cheng, L., Du, P., Liu, Y., 2017. A review of supervised object-based land-cover image classification. *ISPRS Journal of Photogrammetry et Remote Sensing* 130, 277–293. <https://doi.org/10.1016/j.isprsjprs.2017.06.001>
- Ma, L., Liu, Y., Zhang, X., Ye, Y., Yin, G., Johnson, B.A., 2019. Deep learning in remote sensing applications: A meta-analysis et review. *ISPRS Journal of Photogrammetry et Remote Sensing* 152, 166–177. <https://doi.org/10.1016/j.isprsjprs.2019.04.015>

- MacQueen, J., 1967. Some methods for classification et analysis of multivariate observations. Presented at the Proceedings of the Fifth Berkeley Symposium on Mathematical Statistics et Probability, Volume 1: Statistics, The Regents of the University of California.
- Manandhar, R., Odeh, I.O.A., Ancev, T., 2009. Improving the Accuracy of Land Use et Land Cover Classification of Landsat Data Using Post-Classification Enhancement. *Remote Sensing* 1, 330–344. <https://doi.org/10.3390/rs1030330>
- Marceau, D.J., Howarth, P.J., Dubois, J.M., Gratton, D.J., 1990. Evaluation Of The Grey-level Co-occurrence Matrix Method For Land-cover Classification Using Spot Imagery. *IEEE Transactions on Geoscience et Remote Sensing* 28, 513–519. <https://doi.org/10.1109/TGRS.1990.572937>
- Mercier, A., Betbeder, J., Rumiano, F., Baudry, J., Gond, V., Blanc, L., Bourgoïn, C., Cornu, G., Ciudad, C., Marchamalo, M., Pocard-Chapuis, R., Hubert-Moy, L., 2019. Evaluation of Sentinel-1 et 2 Time Series for Land Cover Classification of Forest–Agriculture Mosaics in Temperate et Tropical Landscapes. *Remote Sensing* 11, 979. <https://doi.org/10.3390/rs11080979>
- Michel, J., Youssefi, D., Grizonnet, M., 2015. Stable Mean-Shift Algorithm et Its Application to the Segmentation of Arbitrarily Large Remote Sensing Images. *IEEE Transactions on Geoscience et Remote Sensing* 53, 952–964. <https://doi.org/10.1109/TGRS.2014.2330857>
- Minderhoud, P.S.J., Coumou, L., Erban, L.E., Middelkoop, H., Stouthamer, E., Addink, E.A., 2018. The relation between land use et subsidence in the Vietnamese Mekong delta. *Science of The Total Environment* 634, 715–726. <https://doi.org/10.1016/j.scitotenv.2018.03.372>
- Mitchell, T.M., 1997. *Machine Learning*, McGraw-Hill series in computer science. McGraw-Hill, New York.
- Michel, J., Youssefi, D., Grizonnet, M., 2015. Stable Mean-Shift Algorithm et Its Application to the Segmentation of Arbitrarily Large Remote Sensing Images. *IEEE Transactions on Geoscience et Remote Sensing* 53, 952–964. <https://doi.org/10.1109/TGRS.2014.2330857>
- Moreira, A., Prats-Iraola, P., Younis, M., Krieger, G., Hajnsek, I., Papathanassiou, K.P., 2013. A tutorial on synthetic aperture radar. *IEEE Geoscience et Remote Sensing Magazine* 1, 6–43. <https://doi.org/10.1109/MGRS.2013.2248301>
- Morgan, J.N., Sonquist, J.A., 1963. Problems in the Analysis of Survey Data, et a Proposal. *Journal of the American Statistical Association* 58, 415–434. <https://doi.org/10.2307/2283276>
- Morinaka, Y., Sakamoto, T., Inukai, Y., Agetsuma, M., Kitano, H., Ashikari, M., Matsuoka, M., 2006. Morphological Alteration Caused by Brassinosteroid

Insensitivity Increases the Biomass et Grain Production of Rice¹. *Plant Physiology*. <https://doi.org/10.1104/pp.106.077081>

Mujabar, S., Chandrasekar, N., 2011. A Shoreline Change analysis along the Coast between Kanyakumari et Tuticorin, India using Remote sensing et GIS. *Arabian Journal of Geosciences* 6. <https://doi.org/10.1007/s12517-011-0394-4>

NAS, 1974. NAS The Effects of Herbicides in South Vietnam National Academy of Sciences, Washington (1974) Part a - Summary et Conclusions.

NEDECO, 1993. Mekong Delta Master Plan Study. A Perspective for Suitable Development of Land et Water Resources, Volume I. World Bank.

Nguyen, T.T.H., Bie, C.A.J.M.D., Ali, A., Smaling, E.M.A., Chu, T.H., 2012. Mapping the irrigated rice cropping patterns of the Mekong delta, Vietnam, through hyper-temporal SPOT NDVI image analysis. *International Journal of Remote Sensing* 33, 415–434. <https://doi.org/10.1080/01431161.2010.532826>

NIAPP, 2001. Adjustment plan for agriculture, aquaculture, salt et forest production in South of National Road 1A, Bac Lieu province. [in Vietnamese], Ho Chi Minh, Vietnam.

Niculescu, S., Billey, A., Talab Ou Ali, H., 2019. *Random Forest* Classification using Sentinel-1 et Sentinel-2 series for vegetation monitoring in the Pays de Brest (France). *SPIE j* 10783.

Niculescu, S., Lam, C.N., 2019. Geographic Object-Based Image Analysis of Changes in Land Cover in the Coastal Zones of the Red River Delta (Vietnam). *Journal of Environmental Protection* 10, 413–430. <https://doi.org/10.4236/jep.2019.103024>

Olofsson, P., Foody, G.M., Herold, M., Stehman, S.V., Woodcock, C.E., Wulder, M.A., 2014. Good practices for estimating area et assessing accuracy of land change. *Remote Sensing of Environment* 148, 42–57. <https://doi.org/10.1016/j.rse.2014.02.015>

Olofsson, P., Foody, G.M., Stehman, S.V., Woodcock, C.E., 2013. Making better use of accuracy data in land change studies: Estimating accuracy et area et quantifying uncertainty using stratified estimation. *Remote Sensing of Environment* 129, 122–131. <https://doi.org/10.1016/j.rse.2012.10.031>

Olofsson, P., Kuemmerle, T., Griffiths, P., Knorn, J., Baccini, A., Gancz, V., Viorel, B., Houghton, R., Abrudan, I., Woodcock, C., 2011. Carbon implications of forest restitution in post-socialist Romania. *Environmental Research Letters* 6, 045202. <https://doi.org/10.1088/1748-9326/6/4/045202>

Pham, L.H., Pham, L.T.H., Dang, T.D., Tran, D.D., Dinh, T.Q., 2021. Application of Sentinel-1 data in mapping land-use et land cover in a complex seasonal

landscape: a case study in the coastal area of Vietnamese Mekong Delta. *Geocarto International* 0, 1–18. <https://doi.org/10.1080/10106049.2020.1869329>

- Pham, Q.S., 2004. Study of development of Red River – Thai Binh River estuaries on the basis of Remote Sensing's Information et GIS for rational exploitation of use of territory. PhD thesis on Protection, rational use et generation of natural resources. National University.
- Phan, T.H., 2018. Rice monitoring using radar remote sensing (phdthesis). Université Paul Sabatier - Toulouse III.
- Phan, H., Le Toan, T., Bouvet, A., Lam, N., Duy, T., Zribi, M., 2018. Mapping of Rice Varieties et Sowing Date Using X-Band SAR Data. *Sensors* 18, 316. <https://doi.org/10.3390/s18010316>
- Phung, D., Nguyen-Huy, T., Tran, N.N., Tran, D.N., Doan, V.Q., Nghiem, S., Nguyen, N.H., Nguyen, T.H., Bennett, T., 2021. Hydropower dams, river drought et health effects: A detection et attribution study in the lower Mekong Delta Region. *Climate Risk Management* 32, 100280. <https://doi.org/10.1016/j.crm.2021.100280>
- Pokhrel, Y., Burbano, M., Roush, J., Kang, H., Sridhar, V., Hyndman, D.W., 2018. A Review of the Integrated Effects of Changing Climate, Land Use, et Dams on Mekong River Hydrology. *Water* 10, 266. <https://doi.org/10.3390/w10030266>
- Potere, D., Schneider, A., 2007. A critical look at representations of urban areas in global maps. *GeoJournal* 69, 55–80. <https://doi.org/10.1007/s10708-007-9102-z>
- Quang, N.N., 2002. Vietnam et the sustainable development of the Mekong river basis. *Water Science et Technology* 45, 261–266. <https://doi.org/10.2166/wst.2002.0403>
- Quinlan, J.R., 1986. Induction of Decision Trees. *Mach. Learn* 1, 81–106.
- Rekik, A., Zribi, M., Benjelloun, M., Hamida, A. ben, 2006. A k-Means Clustering Algorithm Initialization for Unsupervised Statistical Satellite Image Segmentation, in: 2006 1ST IEEE International Conference on E-Learning in Industrial Electronics. Presented at the 2006 1ST IEEE International Conference on E-Learning in Industrial Electronics, pp. 11–16. <https://doi.org/10.1109/ICELIE.2006.347204>
- Revilla-Romero, B., Hirpa, F.A., Pozo, J.T., Salamon, P., Brakenridge, R., Pappenberger, F., De Groeve, T., 2015. On the Use of Global Flood Forecasts et Satellite-Derived Inundation Maps for Flood Monitoring in Data-Sparse Regions. *Remote Sensing* 7, 15702–15728. <https://doi.org/10.3390/rs71115702>

- Rodriguez-Galiano, V.F., Ghimire, B., Rogan, J., Chica-Olmo, M., Rigol-Sanchez, J.P., 2012. An assessment of the effectiveness of a random forest classifier for land-cover classification. *ISPRS Journal of Photogrammetry et Remote Sensing* 67, 93–104. <https://doi.org/10.1016/j.isprsjprs.2011.11.002>
- Rosenblatt, F., 1957. *The Perceptron, a Perceiving et Recognizing Automaton Project Para.* Cornell Aeronautical Laboratory.
- Rouse, J., Haas, R.H., Deering, D., Schell, J.A., Harlan, J., 1973. Monitoring the Vernal Advancement et Retrogradation (Green Wave Effect) of Natural Vegetation. [Great Plains Corridor]. undefined.
- Roy, D.P., Wulder, M.A., Loveland, T.R., C.e., W., Allen, R.G., Anderson, M.C., Helder, D., Irons, J.R., Johnson, D.M., Kennedy, R., Scambos, T.A., Schaaf, C.B., Schott, J.R., Sheng, Y., Vermote, E.F., Belward, A.S., Bindaschadler, R., Cohen, W.B., Gao, F., Hipple, J.D., Hostert, P., Huntington, J., Justice, C.O., Kilic, A., Kovalsky, V., Lee, Z.P., Lymburner, L., Masek, J.G., McCorkel, J., Shuai, Y., Trezza, R., Vogelmann, J., Wynne, R.H., Zhu, Z., 2014. Landsat-8: Science et product vision for terrestrial global change research. *Remote Sensing of Environment* 145, 154–172. <https://doi.org/10.1016/j.rse.2014.02.001>
- Rumelhart, D., Hinton, G.E., Williams, R.J., 1986. Learning representations by back-propagating errors. *Nature*. <https://doi.org/10.1038/323533a0>
- Sakamoto, T., Van Phung, C., Kotera, A., Nguyen, K.D., Yokozawa, M., 2009. Analysis of rapid expansion of inland aquaculture et triple rice-cropping areas in a coastal area of the Vietnamese Mekong Delta using MODIS time-series imagery. *Landscape et Urban Planning* 92, 34–46. <https://doi.org/10.1016/j.landurbplan.2009.02.002>
- Salzberg, S.L., 1994. C4.5: Programs for Machine Learning by J. Ross Quinlan. Morgan Kaufmann Publishers, Inc., 1993. *Mach Learn* 16, 235–240. <https://doi.org/10.1007/BF00993309>
- Schiewe, J., 2012. Segmentation of high-resolution remotely sensed data - Concepts, applications et problems. *International Archives of Photogrammetry et Remote Sensing* 34.
- Schmullius, C.C., Evans, D.L., 1997. Review article Synthetic aperture radar (SAR) frequency et polarization requirements for applications in ecology, geology, hydrology, et oceanography: A tabular status quo after SIR-C/X-SAR. *International Journal of Remote Sensing* 18, 2713–2722. <https://doi.org/10.1080/014311697217297>
- Schubert, A., Small, D., Miranda, N., Geudtner, D., Meier, E., 2015. Sentinel-1A Product Geolocation Accuracy: Commissioning Phase Results. *Remote Sensing* 7, 9431–9449. <https://doi.org/10.3390/rs70709431>

- Singh, M., Ahuja, N., 2002. Mean-Shift Segmentation with Wavelet-based Bandwidth Selection. <https://doi.org/10.1109/ACV.2002.1182154>
- Smajgl, A., Toan, T.Q., Nhan, D.K., Ward, J., Trung, N.H., Tri, L.Q., Tri, V.P.D., Vu, P.T., 2015. Responding to rising sea levels in the Mekong Delta. *Nature Climate Change* 5, 167–174. <https://doi.org/10.1038/nclimate2469>
- Spruce, J., Bolten, J., Mohammed, I.N., Srinivasan, R., Lakshmi, V., 2020. Mapping Land Use Land Cover Change in the Lower Mekong Basin From 1997 to 2010. *Front. Environ. Sci.* 8. <https://doi.org/10.3389/fenvs.2020.00021>
- Stibig, H.-J., Achard, F., Fritz, S., 2004. A new forest cover map of continental southeast Asia derived from SPOT-VEGETATION satellite imagery. *Applied Vegetation Science* 7, 153–162. <https://doi.org/10.1111/j.1654-109X.2004.tb00606.x>
- Strahler, A.H., Boschetti, L., Foody, G.M., Friedl, M.A., Hansen, M.C., Herold, M., Morisette, J.T., Stehman, S.V., 2006. Global Land Cover Validation: Recommendations for Evaluation et Accuracy Assessment of Global et Cover Maps.
- Stutz, D., Hermans, A., Leibe, B., 2018. Superpixels: An Evaluation of the State-of-the-Art. *Computer Vision et Image Understanding* 166, 1–27. <https://doi.org/10.1016/j.cviu.2017.03.007>
- Taylor, P., 2014. *The khmer lands of Vietnam: Environment, cosmology et sovereignty.* NUS Press, Singapore.
- Thanh Noi, P., Kappas, M., 2018. Comparison of *Random Forest*, k-Nearest Neighbor, et Support Vector Machine Classifiers for Land Cover Classification Using Sentinel-2 Imagery. *Sensors* 18, 18. <https://doi.org/10.3390/s18010018>
- Thompson, J.R., Laizé, C.L.R., Green, A.J., Acreman, M.C., Kingston, D.G., 2014. Climate change uncertainty in environmental flows for the Mekong River. *Hydrological Sciences Journal* 59, 935–954. <https://doi.org/10.1080/02626667.2013.842074>
- Thuan, N.T., 2006. *The dry season flow in the Mekong Delta: The report collection of the Science Technology conference.* The Institute of Hydrology Technology et Environments.
- Ticehurst, C., Guerschman, J.P., Chen, Y., 2014. The Strengths et Limitations in Using the Daily MODIS Open Water Likelihood Algorithm for Identifying Flood Events. *Remote Sensing* 6, 11791–11809. <https://doi.org/10.3390/rs61211791>
- Tiede, D., Lang, S., Hoffmann, C., 2008. Domain-specific class modelling for one-level representation of single trees, in: Blaschke, T., Lang, Stefan, Hay, G.J. (Eds.), *Object-Based Image Analysis: Spatial Concepts for Knowledge-Driven Remote Sensing Applications*, Lecture Notes in Geoinformation et

Cartography. Springer, Berlin, Heidelberg, pp. 133–151.
https://doi.org/10.1007/978-3-540-77058-9_7

- Tilman, D., 2001. Forecasting Agriculturally Driven Global Environmental Change. *Science* 292, 281–284. <https://doi.org/10.1126/science.1057544>
- Tilman, D., Fargione, J., Wolff, B., D'Antonio, C., Dobson, A., Howarth, R., Schindler, D., Schlesinger, W.H., Simberloff, D., Swackhamer, D., 2001. Forecasting Agriculturally Driven Global Environmental Change. *Science* 292, 281–284. <https://doi.org/10.1126/science.1057544>
- Tomiyasu, K., 1978. Tutorial review of synthetic-aperture radar (SAR) with applications to imaging of the ocean surface. *Proceedings of the IEEE* 66, 563–583. <https://doi.org/10.1109/PROC.1978.10961>
- Tran, H., Tran, T., Kervyn, M., 2015. Dynamics of Land Cover/Land Use Changes in the Mekong Delta, 1973–2011: A Remote Sensing Analysis of the Tran Van Thoi District, Ca Mau Province, Vietnam. *Remote Sensing* 7, 2899–2925. <https://doi.org/10.3390/rs70302899>
- Trung, N., 2006. Comparing land use planning approaches in the Mekong Delta, Vietnam /.
- Trung, N.H., Tri, L.Q., Mensvoort, M.E.F. van, Bregt, A.K., 2007. Application of GIS in land-use planning: a case study in the Coastal Mekong Delta of Vietnam. *International Journal of Geoinformatics* 3, 1–8.
- Truong, T.D., Do, L.H., 2018. Mangrove forests et aquaculture in the Mekong river delta. *Land Use Policy* 73, 20–28. <https://doi.org/10.1016/j.landusepol.2018.01.029>
- van Maren, D.S., 2007. Water et sediment dynamics in the Red River mouth et adjacent coastal zone. *Journal of Asian Earth Sciences, Morphodynamics of the Red River Delta, Vietnam* 29, 508–522. <https://doi.org/10.1016/j.jseaes.2006.03.012>
- Västilä, K., Kummu, M., Sangmanee, C., Chinvanno, S., 2010. Modelling climate change impacts on the flood pulse in the Lower Mekong floodplains. *JOURNAL OF WATER AND CLIMATE CHANGE* 1, 67–86. <https://doi.org/10.2166/wcc.2010.008>
- Vörösmarty, C.J., Green, P., Salisbury, J., Lammers, R.B., 2000. Global Water Resources: Vulnerability from Climate Change et Population Growth. *Science* 289, 284–288. <https://doi.org/10.1126/science.289.5477.284>
- Wackernagel, M., Schulz, N.B., Deumling, D., Linares, A.C., Jenkins, M., Kapos, V., Monfreda, C., Loh, J., Myers, N., Norgaard, R., Randers, J., 2002. Tracking the ecological overshoot of the human economy. *PNAS* 99, 9266–9271. <https://doi.org/10.1073/pnas.142033699>

- Wang, K., Franklin, S.E., Guo, X., He, Y., McDermid, G.J., 2009. Problems in remote sensing of landscapes et habitats. *Progress in Physical Geography: Earth et Environment* 33, 747–768. <https://doi.org/10.1177/0309133309350121>
- Wang, W., Lu, H., Leung, L.R., Li, H.-Y., Zhao, J., Tian, F., Yang, K., Sothea, K., 2017. Dam Construction in Lancang-Mekong River Basin Could Mitigate Future Flood Risk From Warming-Induced Intensified Rainfall. *Geophysical Research Letters* 44, 10,378-10,386. <https://doi.org/10.1002/2017GL075037>
- Weng, Q., 2009. *Remote Sensing et GIS Integration: Theories, Methods, et Applications*.
- White, I., 2002. Water management in the Mekong delta: changes, conflicts et opportunities, in: UNESCO's International Hydrological Programme. Technical Documents in Hydrology, No 61.
- Wilder, M., Phuong, N.T., 2002. The status of aquaculture in the Mekong Delta region of Vietnam: Sustainable production et combined farming systems. *Fisheries science* 68, 847–850. https://doi.org/10.2331/fishsci.68.sup1_847
- Woodcock, C.E., Strahler, A.H., 1987. The factor of scale in remote sensing. *Remote Sensing of Environment* 21, 311–332. [https://doi.org/10.1016/0034-4257\(87\)90015-0](https://doi.org/10.1016/0034-4257(87)90015-0)
- Xian, G., Crane, M., 2005. Assessments of urban growth in the Tampa Bay watershed using remote sensing data. *Remote Sensing of Environment* 97, 203–215. <https://doi.org/10.1016/j.rse.2005.04.017>
- Yang, G., Pu, R., Zhang, J., Zhao, C., Feng, H., Wang, J., 2013. Remote sensing of seasonal variability of fractional vegetation cover et its object-based spatial pattern analysis over mountain areas. *ISPRS Journal of Photogrammetry et Remote Sensing* 77, 79–93. <https://doi.org/10.1016/j.isprsjprs.2012.11.008>
- Yang, J., He, Y., Weng, Q., 2015. An Automated Method to Parameterize Segmentation Scale by Enhancing Intra-segment Homogeneity et Intersegment Heterogeneity. *IEEE Geoscience et Remote Sensing Letters* 12, 1282–1286. <https://doi.org/10.1109/LGRS.2015.2393255>
- Zhou, Chellappa, 1988. Computation of optical flow using a neural network, in: *IEEE 1988 International Conference on Neural Networks*. Presented at the IEEE 1988 International Conference on Neural Networks, pp. 71–78 vol.2. <https://doi.org/10.1109/ICNN.1988.23914>
- Zhou, H., Li, X., Schaefer, G., Celebi, M.E., Miller, P., 2013. Mean shift based gradient vector flow for image segmentation. *Computer Vision et Image Understanding* 117, 1004–1016. <https://doi.org/10.1016/j.cviu.2012.11.015>
- Zhu, X.X., Tuia, D., Mou, L., Xia, G.-S., Zhang, L., Xu, F., Fraundorfer, F., 2017. Deep learning in remote sensing: a review. *IEEE Geosci. Remote Sens. Mag.* 5, 8–36. <https://doi.org/10.1109/MGRS.2017.2762307>

ANNEXE

1. Points d'observation et de validation des résultats sur le terrain

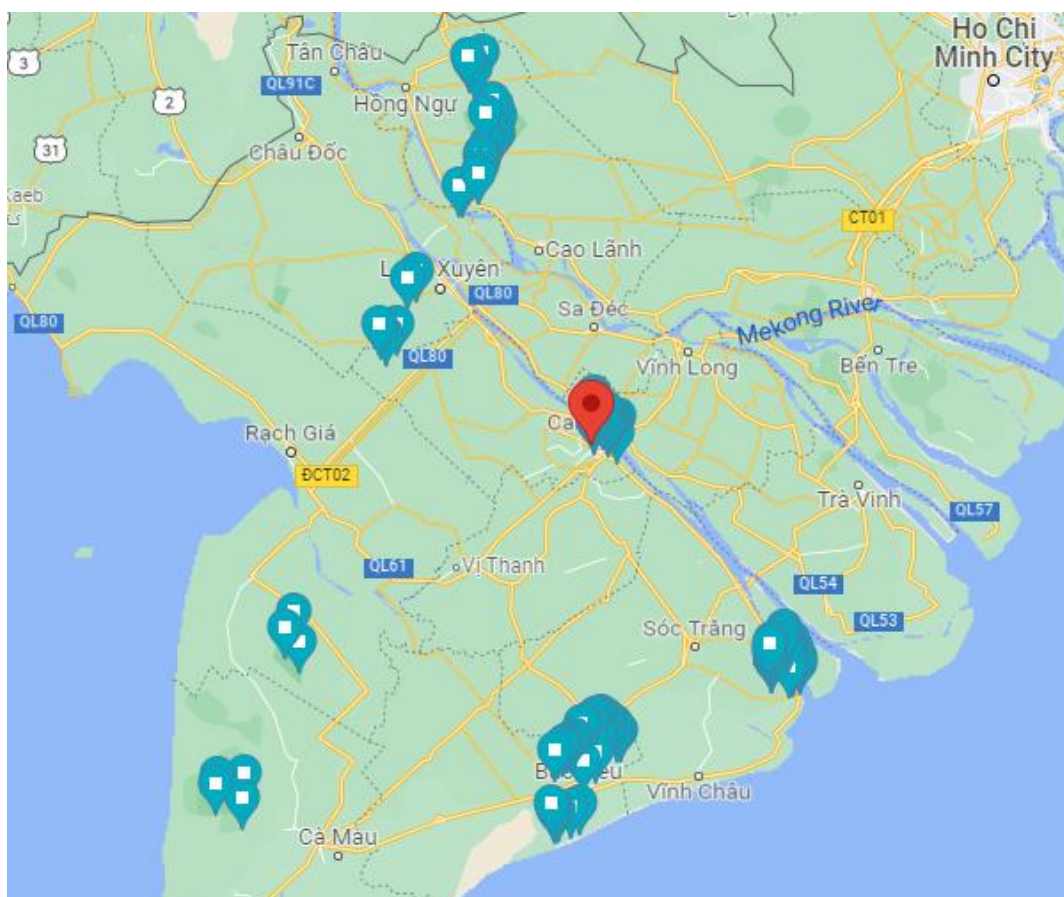


Figure 48 : Points d'observation et de validation dans le delta du Mékong.

Tableau 31: Nombre de points d'observation.

Classe	Nombre de points
Forêt	83
Rizière	126
Jardin	123
Village	73
Végétation basse	45
Eau Permanente	127
Canne à sucre	50
Cocotier	30
La somme	657

2. Calcul du coefficient de rétrodiffusion




Figure 49 : Profils VH temporel des classes de l'occupation du sol en 2019.




Figure 50 : Profils VV temporel des classes de l'occupation du sol en 2019.




Figure 51 : Profils VH temporel des classes de l'occupation du sol en 2020.

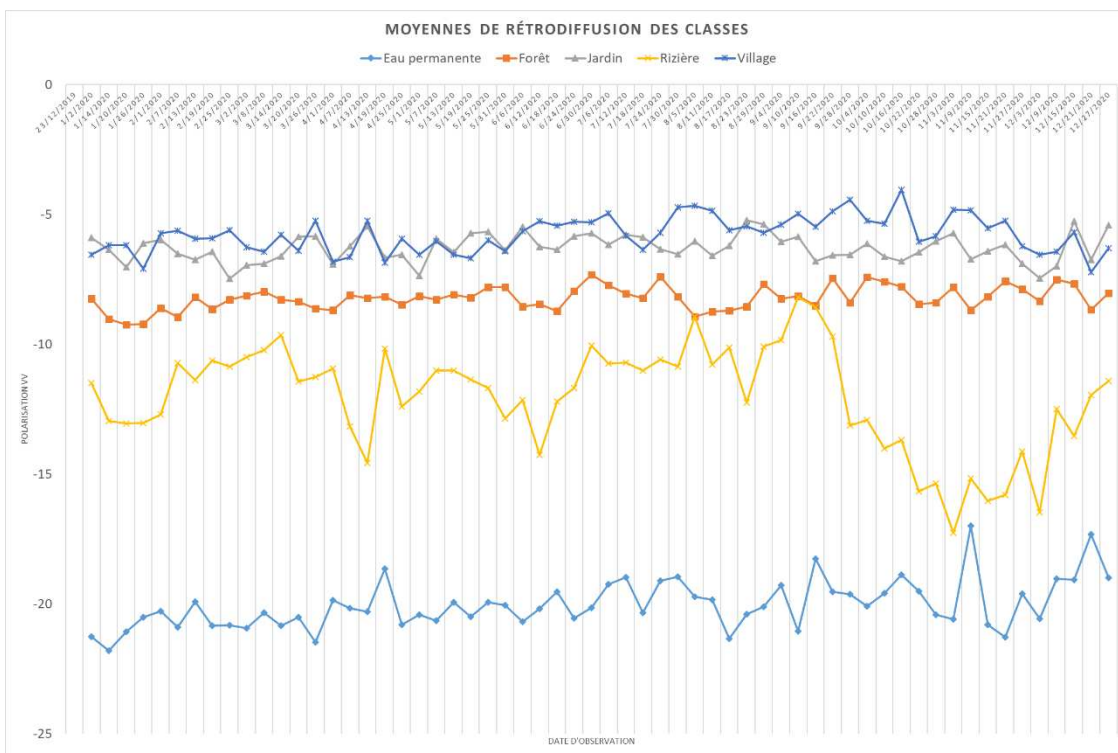


Figure 52 : Profils VV temporel des classes de l'occupation du sol en 2020

3. Paramétrage des modèles d'apprentissage automatique

Tableau 32 : Optimisation des paramètres (Range, gamma) pour construire un modèle SVM pour des données 2016,2017, 2018 afin de cartographier l'occupation du sol du delta du fleuve Rouge

		Données 2016	Données 2017	Données 2018
Range	Gamma	précision	précision	précision
0.01	0.1	0.1969	0.2146	0.2055
0.01	1	0.3526	0.2146	0.2055
0.01	100	0.3541	0.2146	0.3111
1	0.1	0.7236	0.4873	0.6460
1	1	0.8396	0.7651	0.8163
1	100	0.8992	0.8333	0.8810
100	0.1	0.9053	0.8358	0.8791
100	1	0.9496	0.8787	0.9314
100	100	1.0	0.9671	0.9857

4. Python codes des modèles d'apprentissage à structure profonde.

Tableau 32 : Code Python du modèle Multilayer Perceptron

<pre> model = Sequential() # Couche entrée input_layer = input_shape=(20,) # Première couche model.add(Dense(32, activation=None, input_layer)) # Deuxième couche model.add(Dense(64, activation='relu')) # Troisième couche model.add(Dense(64, activation='relu')) # Couche sortie model.add(Dense(7, activation='softmax')) model.summary() </pre>	<pre> Model: "sequential" Layer (type) Output Shape Param # ----- dense (Dense) (None, 32) 672 dense_1 (Dense) (None, 64) 2112 dense_2 (Dense) (None, 64) 4160 dense_3 (Dense) (None, 7) 455 ----- Total params: 7,399 Trainable params: 7,399 Non-trainable params: 0 </pre>
---	---

Tableau 33 : Code Python du modèle Convolutional Neural Network

<pre> input_shape = (8, 8, 4) num_classes=6 model = Sequential([keras.Input(shape=input_shape), # Première couche convolutif layers.Conv2D(64, kernel_size=(3, 3), activation="relu"), # Première couche Max-Pooling layers.MaxPooling2D((2, 2),padding="same"), # Deuxième couche convolutif layers.Conv2D(64, kernel_size=(3, 3), activation="relu"), # Deuxième couche Max-Pooling layers.MaxPooling2D((2, 2),padding="same"), layers.Flatten(), # Première Couche des perceptron layers.Dense(64, activation="relu"), # Couche sortie layers.Dense(num_classes, activation="softmax"),]) model.summary() </pre>	<pre> Model: "sequential" Layer (type) Output Shape Param # ----- conv2d (Conv2D) (None, 6, 6, 64) 2368 max_pooling2d (MaxPooling2D) (None, 3, 3, 64) 0 conv2d_1 (Conv2D) (None, 1, 1, 64) 36928 max_pooling2d_1 (MaxPooling2D) (None, 1, 1, 64) 0 flatten (Flatten) (None, 64) 0 dense (Dense) (None, 64) 4160 dense_1 (Dense) (None, 6) 390 ----- Total params: 43,846 Trainable params: 43,846 Non-trainable params: 0 </pre>
---	--

Titre : Méthodes de Machine Learning pour le suivi de l'occupation du sol des deltas du Viêt-Nam.

Mots clés : méthodes d'apprentissage automatique, delta du Vietnam, suivi de l'occupation du sol,

Résumé : Le développement socio-économique au Vietnam est associé à l'existence des grands deltas fluviaux. En outre, les facteurs environnementaux tels que la sécheresse et l'inondation jouent un rôle important dans le changement de l'occupation du sol au niveau de ces deltas. Ces changements ne sont pas sans impact sur l'équilibre naturel et économique du pays. Dans cette optique, cette thèse a pour objectifs de proposer des méthodes de traitement des données satellites pour une cartographie et suivi efficaces de l'occupation du sol au niveau des deux principaux deltas du Viêt-Nam, fleuve rouge et du

Mékong. En effet, un travail expérimental a été effectué en vérifiant et évaluant l'apport du traitement d'images multi-capteurs par de nombreuses approches de segmentation d'image et d'apprentissage automatique peu profond et profond. Ainsi, un modèle de Convolutional Neural Network (CNN) adapté au contexte de l'étude, a démontré sa robustesse pour la détection et la cartographie de l'occupation du sol afin de caractériser l'aléa de l'inondation et d'analyser les enjeux.

Title : Machine Learning methods for monitoring land use in deltas of Vietnam

Keywords : Machine learning, delta of Vietnam, monitoring of Land cover/Land use

Abstract : Socio-economic development in Vietnam is associated with the existence of large fluvial deltas. Furthermore, environmental factors such as dryness and flooding have an important role in the change of land use/land cover within these deltas. These changes have an impact on the natural and economic balance of the country. In this perspective, the objectives of the present thesis are to suggest processing methods of satellite data for an efficient mapping and monitoring of land use in the two main deltas of Vietnam, the Red River and the Mekong

Delta. Indeed, experimental work has been carried out by verifying and evaluating the contribution of multi-sensor image processing through various image segmentation approaches and machine/deep learning algorithms. Thus, a Convolutional Neural Network (CNN) model adapted to the context of the study demonstrated its robustness for the detection and mapping of land use in order to characterise the flood hazard and analyse the issues at risk.