



HAL
open science

Cartographie des formations végétales naturelles à l'échelle régionale par classification de séries temporelles d'images satellitaires

Emmanuelle Cano

► **To cite this version:**

Emmanuelle Cano. Cartographie des formations végétales naturelles à l'échelle régionale par classification de séries temporelles d'images satellitaires. Géographie. Université Rennes 2, 2016. Français. NNT : 2016REN20024 . tel-01346525

HAL Id: tel-01346525

<https://theses.hal.science/tel-01346525>

Submitted on 19 Jul 2016

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.



**UNIVERSITE
BRETAGNE
LOIRE**

**Cartographie des formations
végétales naturelles à l'échelle
régionale par classification de
séries temporelles d'images
satellites**

Thèse soutenue le 15 juin 2016 devant le jury composé de :

Marc ROBIN

Professeur, Université de Nantes / *Président*

Thomas HOUET

Chargé de recherche HDR, Université Jean Jaurès, Toulouse / *Rapporteur*

Catherine MERING

Professeure, Université Paris-Diderot / *Rapporteur*

Hervé QUENOL

Directeur de recherches, CNRS / *Examineur*

Michel DESHAYES

Ingénieur de recherche, GEO, Genève / *Examineur*

Véronique CHERET

Enseignant-chercheur EI Purpan, UMR Dynafor, Toulouse / *Co-directrice de thèse*

Laurence HUBERT-MOY

Professeure, Université Rennes 2 / *Directrice de thèse*

Illustration : ZHUO YUE, "Night extinguished forest", Acrylic on canvas - 20x20cm
<http://zhuo-yue.e-monsite.com>

Remerciements

Evoquer toutes les personnes croisées lors de cette aventure afin de pouvoir les remercier est source de joie, car c'est à cette occasion que je me rends vraiment compte à quelle point elles sont nombreuses : chacune de ces rencontres est une chance.

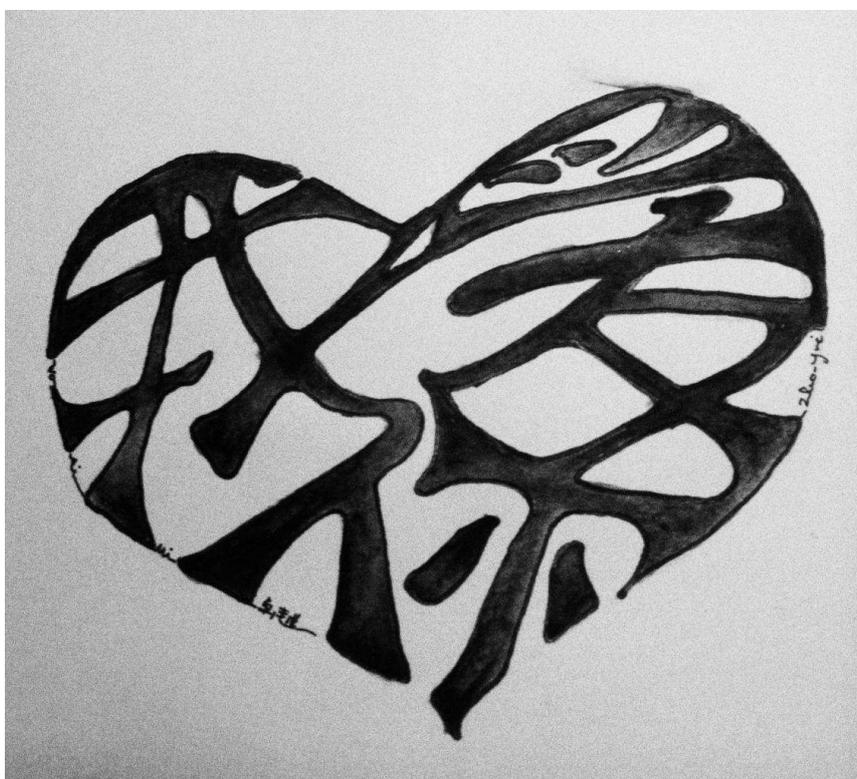
Je tiens à remercier en tout premier lieu Véronique Chéret et Jean-Philippe Denux pour leur encadrement durant ces années. Je tiens également à remercier Laurence Hubert-Moy, pour tous ses encouragements et son attachement à valoriser tous les aspects du travail que j'ai pu fournir.

Mes remerciements vont également à Jordi Inglada et Matthieu Fauvel pour leurs judicieux conseils et le suivi technique et scientifique de mes résultats. Un grand merci à l'équipe de l'UMR Tetis, notamment à Mar Bisquert-Perles pour sa collaboration cordiale et toujours efficace dans le cadre de certains de mes travaux. Mes remerciements vont également à Danielle Ducrot et Isabel Rodes, pour leur accueil chaleureux et pour les informations précieuses qu'elles m'ont transmises. Je remercie particulièrement Anne Jacquin et Sylvie Duthoit, pour les encouragements réguliers qu'elles ont su me prodiguer, qui m'ont permis de garder le recul nécessaire dans les moments de doute. De façon générale, je remercie l'ensemble des professionnels de l'Ecole d'Ingénieurs de Purpan, mais aussi de l'INRA de Castanet Tolosan et notamment de l'UMR DYNAFOR avec qui j'ai pu avoir des échanges variés, mais toujours intéressants, constructifs et agréables.

Impossible de ne pas penser à l'ensemble des doctorants de l'EI-Purpan et de l'INRA : je retiens d'excellents souvenirs, de grand moments de rigolade, d'échanges amicaux et de débats totalement décousus et surréalistes, liés au débordement de cerveaux à l'ébullition parfois difficile à maîtriser, qui ont parfaitement contribué à compenser le sérieux de ces années. Un grand merci pour chacun d'entre eux.

A personnes spéciales, remerciements spéciaux... à mes colocataires de bureau, qui ont dû me supporter au quotidien, y compris dans les moments d'incompatibilité d'humeur avec mon ordinateur. La thèse n'aurait vraiment pas été la même sans eux. Merci à Jonas, pour sa présence unique, drôle, touchante, déconcertante. Je n'oublierai pas sa technique imbattable de dispersion du tabac sur matériel bureautique, ni ses irréelles tours de gobelets de café, ni nos débats pour refaire le monde. Merci de m'avoir transmis la conduite à tenir en cas d'alerte zombie. Merci à Antoine, pour son sang-froid, sa patience et son attitude classe en toutes circonstances. Je ne comprends toujours rien au rugby, mais il aura le grand mérite d'avoir essayé de me l'expliquer. Je retiens malgré tout la notion d'engagement total, et surtout, bien sûr, son imbattable rire sardonique, qui va bien me manquer. Merci à Caroline, pour son soutien indéfectible, pour nos fous-rires, pour ce titre de meilleure colocataire de bureau 2012-2016 bien mérité et pour tous ces moments qui vont également beaucoup me manquer. Heureusement, nous avons appris ensemble à verticaliser notre esprit, ça nous a rendues plus fortes.

Mes plus chaleureux remerciements vont à l'ensemble de mes amis, toulousains comme parisiens. Merci notamment à Chloé, Marianne, Marie, Mary-Lynn, Alain, Johnn, Philo, Laure, Morgane et Nathalie, pour les superbes moments d'amitié passés et à venir. Merci à Joseph et à Aurélien. Tout ça n'aurait pas été possible sans vous, famille et proches. Les mots me manquent et un simple merci semble bien fade. Je remercie de tout cœur Xavier et ma famille de cœur toulousaine. Je remercie Cécile, ma sœur de cœur, qui est toujours là quoi qu'il arrive de bon ou de mauvais, pour son soutien indéfectible. Merci à ma famille, pour cet amour inconditionnel, en particulier à Chantal et Nicolas, à Benjamin, Anne-Sophie, Clémence et Mathilde, et à mes parents : c'est vous qui m'avez rendue capable de mener à bien cette aventure.



<http://zhuo-yue.e-monsite.com>

Liste des sigles et acronymes

ACP : Analyse en Composantes Principales
CESBIO : Centre d'Etudes Spatiales de la Biosphère
CNES : Centre National d'Etudes Spatiales
EC : Erreur de Commission
EO : Erreur d'Omission
EVI : Enhanced Vegetation Index
FAO : Food and Agriculture Organization
G : Green (vert)
IFN : Inventaire Forestier National
IGN : Institut national de l'information géographique et forestière
HLU : Homogeneous Landscape Unit (unité paysagère homogène)
HRS : Haute Résolution Spatiale
K : Indice de Kappa
LIDAR : Light Detection And Ranging
LPDAAC : Land Processes Distributed Active Archive Center
MFE50 : Mapa Forestal de España (carte forestière d'Espagne, ech. 1/50 000)
MFPA : Mapa Forestal del Principat d'Andorra (carte forestière de la Principauté d'Andorre)
MIR : Mid-Infrared (Infrarouge moyen)
ML : Maximum Likelihood (maximum de vraisemblance)
MNT : Modèle Numérique de Terrain
MODIS : MODerate Imaging Spectroradiometer
MRS : Moyenne Résolution Spatiale
MVC : Maximum Value Composite
NDVI : Normalized Difference Vegetation Index
NIR : Near Infrared (Infrarouge proche)
OA : Overall Accuracy (précision globale)
OBIA : Object-Based Image Analysis
OPCC : Observatoire Pyrénéen du Changement Climatique
OTB : Orpheo Tool Box
PP : Precision Producteur
POCTEFA : Programme Opérationnel de Coopération Territoriale Espagne – France - Andorre
PU : Precision Utilisateur
R / RED : Rouge
RF : Random Forest
SRTM : Shuttle Radar Topography Mission
SVM : Support Vector Machine

TR : taux de rejet

USGS : United States Geological Survey

Liste des communications et publications

- Publications dans des revues à comité de lecture :

Cano, E., Denux, J.P., Bisquert, M., Hubert-Moy, L., et Chéret, V. (accepté), Improved forest cover mapping based on MODIS time series and landscape stratification, *International Journal of Remote Sensing*, *sous révisions mineures*.

- En préparation pour soumission avant fin 2016 :

Denux, J.P., **Cano, E.**, Hubert-Moy, L., et Chéret, V., Comparison of maximum likelihood, support vector machine and random forest for forest types mapping with MODIS time series.

Cano, E., Denux, J.P., Hubert-Moy, L., et Chéret, V., Comparison of forest cover mapping using MODIS time series and multirate high spatial resolution images.

- Communication orale

Cano, E., Denux, J.P., Hubert-Moy, L., et Chéret, V., « Comparison of maximum likelihood, support vector machine and random forest for forest types mapping » in ForestSAT 2014, Rival del Garda, Italie, 4-7 Novembre.

- Communication par affiche

Cano, E., Denux, J.P., Bisquert, M., Hubert-Moy, L., et Chéret, V. « Contribution of an object-oriented image segmentation to forest cover mapping » in GV2M 2014, Avignon, 3-7 Février.

Cano, E., Denux, M., Hubert-Moy, L., et Chéret, V. « Contributions of maximum likelihood, support vector machine and random forest to forest cover mapping » in EARSEL 2014, Berlin, 17-18 Mars.

Sommaire

Remerciements	5
Liste des sigles et acronymes	7
Liste des communications et publications	9
Sommaire	10
Liste des figures.....	14
Liste des tableaux	18
Introduction générale.....	20
Chapitre 1 : Contexte, démarche et objectifs de la thèse.....	23
1 Les caractéristiques spectrales et temporelles de la végétation	24
2 La classification de la végétation.....	28
2.1 La classification d'images de télédétection	28
2.2 La procédure de classification supervisée	29
2.2.1 Définition du besoin cartographique et des caractéristiques du site d'étude.....	30
2.2.2 Elaboration de la nomenclature et sélection des pixels d'entraînement et de validation	30
2.2.3 Collecte des données d'entrée	32
2.2.4 Choix d'un algorithme de classification adapté	33
2.2.5 Traitement post-classification	36
2.2.6 Evaluation de la qualité des résultats.....	37
2.3 Les limites de la classification supervisée.....	40
3 Démarche et objectifs	42
3.1 Définition d'une procédure de classification supervisée adaptée à la cartographie des essences forestières à une échelle régionale.....	42
3.2 Objectifs de thèse et organisation du mémoire.....	44
Chapitre II : Site d'étude et données	45
1 Sites d'étude	45
1.1 Site d'étude MRS	45
1.1.1 Caractéristiques géographiques	45
1.1.2 Caractéristiques climatiques.....	47
1.1.3 Principales caractéristiques de la végétation	49
1.2 Site d'étude HRS	53
1.2.1 Caractéristiques géographiques	54
1.2.2 Caractéristiques des peuplements forestiers	55

2	Les données	56
2.1	Données satellitaires.....	56
2.1.1	Données à moyenne résolution spatiale.....	56
2.1.2	Données à haute résolution spatiale.....	57
2.2	Données ancillaires et complémentaires.....	59
2.3	Données de référence et nomenclature forestière.....	60
2.3.1	Données de référence	60
2.3.2	Nomenclature pour les classifications	64
2.4	Données de validation	66
2.4.1	Les données cartographiques.....	66
2.4.2	Les données de placettes	66
Chapitre III : Evaluation de l'apport de la stratification à la classification par maximum de vraisemblance.....		68
1	Introduction	68
2	Méthodes	69
2.1	Constitution des séries temporelles d'images.....	69
2.2	Délimitation des unités paysagères homogènes	69
2.3	Définition et caractérisation des strates	70
2.3.1	Définition des strates	70
2.3.2	Calcul d'indices descripteurs des strates	71
2.4	Classification supervisée	73
2.5	Analyse de l'influence des caractéristiques topographiques et paysagères.....	74
3	Résultats.....	75
3.1	Stratification	75
3.1.1	Délimitation des unités paysagères homogènes	75
3.1.2	Définition des strates	76
3.1.3	Caractérisation des strates	77
3.2	Effet de la stratification sur la qualité des classifications.....	77
3.2.1	Analyse au niveau global.....	77
3.2.2	Analyse par strate	80
3.3	Analyse de l'influence des caractéristiques topographiques et paysagères des strates	81
3.3.1	Influence de la surface de strate	82
3.3.2	Influence de la variabilité de l'altitude.....	83
3.3.3	Influence de l'écart type de l'aire des patches.....	84
3.3.4	Influence du nombre de classes.....	85
4	Discussion-conclusion	86

Chapitre IV : Amélioration et comparaison de trois procédures de classification	89
1 Introduction	89
2 Méthodes	91
2.1 Organisation des procédures de classification.....	91
2.1.1 Paramétrage des algorithmes de classification	91
2.1.2 Jeu d'entraînement.....	95
2.1.3 Organisation temporelle des séries d'images	97
2.1.4 Composition radiométrique des séries.....	98
2.1.5 Ajout de données ancillaires.....	98
2.2 Enchaînement des étapes de traitement.....	99
2.3 Interprétation des résultats de classification.....	100
2.3.1 Analyse temporelle et spatiale des résultats	100
2.3.2 Analyse thématique des résultats.....	101
3 Résultats.....	102
3.1 Détermination des procédures de classification optimales.....	102
3.1.1 Choix du taux d'échantillonnage.....	102
3.1.2 Choix du seuil de taux de classe majoritaire	105
3.1.3 Choix de l'organisation des séries	106
3.2 Interprétation des résultats de classification.....	117
3.2.1 Analyse temporelle et spatiale des résultats	117
3.2.2 Analyse thématique des résultats.....	126
4 Discussion - conclusion	130
4.1 Bilan sur l'amélioration des procédures de classification	130
4.2 Bilan sur l'analyse temporelle et spatiale des résultats	131
4.3 Bilan sur l'interprétation thématique des résultats	131
4.4 Analyse critique de la carte forestière de référence.....	132
4.5 Perspectives d'approfondissement	133
Chapitre V: Apport d'une série temporelle à haute résolution spatiale.....	134
1 Méthodes	134
1.1 Procédures de classification	134
1.1.1 Site d'étude et nomenclature	134
1.1.2 Paramétrage des algorithmes de classification	135
1.1.3 Jeu d'entraînement - Variation du taux d'échantillonnage.....	135
1.1.4 Constitution des séries d'images	136
1.2 Enchaînement des étapes de traitement.....	138
1.3 Interprétation des résultats de classification.....	139

1.3.1	Analyse spatiale et thématique des résultats.....	139
1.3.2	Comparaison avec les résultats issus des données MODIS.....	139
2	Résultats.....	140
2.1	Détermination des procédures de classification optimales.....	140
2.1.1	Choix du taux d'échantillonnage.....	140
2.1.2	Choix de la composition des séries.....	143
2.2	Interprétation des résultats de classification.....	148
2.2.1	Analyse spatiale et thématique des résultats.....	148
2.2.2	Comparaison avec les résultats issus des données MODIS.....	153
3	Discussion-conclusion.....	158
3.1	Bilan sur la détermination des procédures de classification optimales.....	158
3.2	Bilan de l'analyse thématique et spatiale.....	159
3.3	Bilan de la comparaison avec les résultats issus des données MODIS.....	160
	Conclusion générale.....	162
	Bibliographie.....	165

Liste des figures

Figure 1 : Profil spectral d'une végétation active.....	24
Figure 2 : Profils annuels de NDVI de formations forestières atlantiques (a) et de formations méditerranéennes (b). Source : (Chéret et Denux, 2011)	26
Figure 3 : Etapes fondamentales d'une procédure de classification supervisée « directe » par pixel, d'après (Dengsheng et al., 2011).....	29
Figure 4 : Attribution d'une classe à différents pixels selon l'approche probabiliste du maximum de vraisemblance.....	33
Figure 5 : Séparation des classes selon l'algorithme SVM : définition de l'hyperplan de séparation à marge maximale.	34
Figure 6 : Séparation des classes selon l'algorithme random forest : séparations successives par une suite d'arbres de décision générés aléatoirement.	35
Figure 7 : Localisation des sites d'étude (sources : GEOFLA (IGN), BD CARTHAGE, SRTM)	46
Figure 8 : Précipitations moyennes annuelles (mm/an) du site d'étude de 1950 à 2000 (source : http://www.worldclim.org/current).	48
Figure 9 : Températures moyennes annuelles (°C) du site d'étude de 1950 à 2000 (source : http://www.worldclim.org/current).	48
Figure 10 : Principales formations végétales du site d'étude MRS (sources : IGN, MFE50, MFA) ...	50
Figure 11 : Hêtre (à gauche) et chêne sessile (à droite). Crédits : J.M. Savoie, EI-Purpan.....	51
Figure 12 : Sapin pectiné (à gauche) et pin sylvestre (à droite). Crédits : J.M. Savoie, EI-Purpan.	52
Figure 13 : Pin à crochets. Crédits : J.M. Savoie, EI-Purpan.	52
Figure 14 : Lande alpine (à gauche) et alternance de pelouse alpine et de sol nu (à droite). Crédits : J.M. Savoie, EI-Purpan.....	53
Figure 15 : Glacier de la Maladeta (versant espagnol). Crédits : J.M. Savoie, EI-Purpan.....	53
Figure 16: Localisation du site d'étude HRS (sources : GEOFLA (IGN), IFN (IGN), BD CARTHAGE, SRTM, MFE50).....	54
Figure 17: Principales formations végétales du site d'étude HRS (sources : GEOFLA (IGN), IFN (IGN), BD CARTHAGE, MFE50).	55
Figure 18 : Distribution des images Deimos sur le profil phénologique moyen du Hêtre (en rouge les dates retenues, en bleu les dates rejetées).....	59
Figure 19 : Contour des pixels MODIS superposé à la carte de référence. En contour jaune, les pixels présentant un taux de classe majoritaire inférieur à 50%.	66
Figure 20 : Démarche générale.....	68
Figure 21 : Résultats de l'Analyse en Composantes Principales (ACP) : a) pour les deux premiers axes factoriels (PC1 et PC2) des séries temporelles d'EVI (EVI_mois) ; b) pour les deux premiers axes factoriels (PC1 et PC2) des 5 indices de texture (Dissi : dissimilarité ; SecMom : Moment Secondaire ; Homo : Homogénéité) et de l'EVI pour le mois d'avril (04).	75
Figure 22: Résultats obtenus (courbes de Zhang et Johnson) à partir de trois dates d'EVI et pour chacun des 5 indices de texture moyennés sur une période de 5 ans (2007-2011) : a) moment secondaire, b) contraste, c) dissimilarité, d) homogénéité, et e) entropie.	76
Figure 23: Stratification du site d'étude MRS obtenue après fusion et élimination des strates critiques. 25 strates sont délimitées.....	76
Figure 24: Relation entre valeurs de TR et valeurs de K pour les 25 strates avec et sans stratification et pour la période 2007-2009.	80

Figure 25: Relation entre écart de K et écart de TR pour les 25 strates et pour la période 2007-2009.	80
Figure 26 : a) Relation entre la valeur de K à la strate avec stratification et la surface de strate (ha) pour la période 2007-2009; b) Relation entre la valeur de K à la strate sans stratification et la surface de strate (ha) pour la période 2007-2009.....	81
Figure 27: Relation entre la surface de strate (ha) et l'écart de K pour la période 2007-2009.....	82
Figure 28: Surface de végétation à classer pour les 25 strates, classes par groupe et par surface décroissante.	83
Figure 29 : Relation entre l'écart-type de l'altitude (m) et l'écart de K pour la période 2007-2009, en considérant les groupes de strates A; B et C.	84
Figure 30: Relation entre l'écart-type de l'aire des patches (ha) et l'écart de K pour la période 2007-2009, en considérant les groupes de strates A, B et C.....	84
Figure 31: Relation entre le nombre de classes et l'écart de K pour la période 2007-2009 en considérant les groupes A, B et C.	85
Figure 32 : Démarche générale de la première partie de la procédure de comparaison des trois algorithmes de classification.	90
Figure 33 : Valeur de l'indice de Kappa en fonction de la profondeur de l'arbre. Pour ces tests, on a conservé la valeur par défaut des autres paramètres, notamment du nombre d'arbres (fixé à 100) et du nombre de variables (fixé à 0).	93
Figure 34 : Indice de Kappa en fonction du nombre de variables pour le tirage aléatoire. Pour ces tests, on a conservé la valeur par défaut des autres paramètres, notamment le nombre d'arbres (fixé à 100) et la valeur optimale de la profondeur de l'arbre (fixée à 24).	93
Figure 35 : Indice de Kappa en fonction du nombre d'arbres. Pour ces tests, on a conservé la valeur optimale du nombre d'arbres (fixé à 500) et de la profondeur de l'arbre (fixée à 24) ainsi que la valeur par défaut des autres paramètres.....	94
Figure 36 : Représentation schématique de la composition des séries étudiées.....	97
Figure 37 : Récapitulatif des modalités techniques d'optimisation et de comparaison.....	100
Figure 38 : Variation de la précision de classification en fonction du taux d'échantillonnage pour ML. Modalités constantes : série non moyennée de NDVI d'une année complète (2000) et taux de classe majoritaire de 50%.	102
Figure 39 : Variation de la précision de classification en fonction du taux d'échantillonnage pour SVM. Modalités constantes : série non moyennée de NDVI d'une année complète (2000) et taux de classe majoritaire de 50%.	103
Figure 40 : Variation de la précision de classification en fonction du taux d'échantillonnage pour RF. Modalités constantes : série non moyennée de NDVI d'une année complète (2000) et taux de classe majoritaire de 50%.	103
Figure 41 : Variation du temps de calcul en fonction du taux d'échantillonnage pour les 3 méthodes de classification.....	104
Figure 42 : Variation de l'indice de Kappa en fonction du taux d'échantillonnage pour les trois méthodes de classification.....	104
Figure 43 : Evolution de l'indice de Kappa en fonction du taux de classe majoritaire pour les trois méthodes en configuration optimale du taux d'échantillonnage.	105
Figure 44 : Valeur de l'indice de Kappa pour la série temporelle de NDVI non moyennée pour la méthode du maximum de vraisemblance (période 2000-2002).	107
Figure 45: Valeur de l'indice de Kappa pour la série temporelle de NDVI moyennée pour la méthode du maximum de vraisemblance (période 2000-2002).	107
Figure 46 : Valeur de l'indice de Kappa pour la série temporelle de NDVI non moyennée pour la méthode SVM (période 2000-2002).....	108

Figure 47 : Valeur de l'indice de Kappa pour la série temporelle de NDVI moyennée pour la méthode SVM (période 2000-2002).	108
Figure 48 : Valeur de l'indice de Kappa pour la série temporelle de NDVI non moyennée pour la méthode RF (période 2000-2002).	109
Figure 49 : Valeur de l'indice de Kappa pour la série temporelle de NDVI moyennée pour la méthode RF (période 2000-2002).	109
Figure 50 : Valeur de l'indice de Kappa selon la durée de la série temporelle d'EVI non moyennée pour la méthode ML (période 2000-2002).	111
Figure 51 : Valeur de l'indice de Kappa selon la durée de la série temporelle d'EVI non moyennée pour la méthode SVM (période 2000-2002).	111
Figure 52 : Valeur de l'indice de Kappa selon la durée de la série temporelle d'EVI non moyennée pour la méthode Random Forest (période 2000-2002).	111
Figure 53 : Valeur de l'indice de Kappa selon la durée pour le maximum de vraisemblance et pour les séries hors hiver non moyennées de NDVI, R+NIR et R+NIR+MIR (période 2000-2002).	113
Figure 54 : Valeur de l'indice de Kappa selon la durée pour la méthode SVM et pour les séries complètes non moyennées de NDVI, R+NIR et R+NIR+MIR (période 2000-2002).	114
Figure 55 : Valeur de l'indice de Kappa selon la durée pour la méthode Random Forest et pour les séries complètes non moyennées de NDVI, R+NIR et R+NIR+MIR (période 2000-2002).	114
Figure 56 : Evolution de l'indice de Kappa en fonction de l'organisation temporelle et de la composition radiométrique des séries, pour les 3 algorithmes de classification.	116
Figure 57 : Cartes des pixels bien et mal classés avec les algorithmes ML, SVM et RF pour la série 2000-2002 - procédures appliquées en configurations optimales.	119
Figure 58 : Proportion de pixels classés correspondant à chaque valeur de fréquence pour la période 2000-2014 et pour chaque méthode de classification.	120
Figure 59 : Proportion de pixels selon nombre classes affectées pour la période 2000-2014 et pour chaque méthode de classification.	121
Figure 60 : Cartes du nombre de classes affectées pour la période 2000-2014 (variété) pour chaque algorithme de classification.	122
Figure 61 : Stabilité temporelle des résultats pour les 3 méthodes de classification : proportion de pixels toujours affectés à la même classe, en distinguant les classements identiques (pixels stables et bien classés) et différents de la référence (pixels stables et mal classé).	124
Figure 62 : Stabilité temporelle des résultats pour RF (classification en configuration optimale)	125
Figure 63 : Surface moyenne de polygone de la cartographie de référence (ha) en fonction de la valeur de fréquence de bon classement.	126
Figure 64 : Valeurs moyennes de F-Score par classe pour les 3 méthodes étudiées (moyenne des 13 classifications), triées par ordre décroissant des valeurs obtenues avec RF.	126
Figure 65 : Extrait des principales confusions de la classification 2000-2003 (RF). Les limites en noir sont celles de la cartographie forestière.	129
Figure 66: Répartition des dates d'acquisition des images DEIMOS par rapport au cycle phénologique de la hêtraie.	137
Figure 67: récapitulatif de l'enchaînement des étapes de traitement des séries d'images.	138
Figure 68: Variation de l'indice de Kappa en fonction du taux d'échantillonnage pour SVM et RF.	140
Figure 69: Evolution des précisions producteur (PP) et utilisateur (PU) en fonction du taux d'échantillonnage, pour SVM et RF.	142
Figure 70: Variation de l'indice de Kappa en fonction de la série, de la composition radiométrique et de l'algorithme (RF et SVM).	143

Figure 71: Evolution des précisions producteur et utilisateur et des erreurs d'omission et de commission de la formation du sapin pectiné avec la variation du nombre de dates pour SVM (taux d'échantillonnage optimal de 1%) et RF (taux d'échantillonnage optimal de 4,5%).	145
Figure 72: Variation de l'indice de Kappa en fonction de l'ajout de données ancillaires (altitude et rayonnement net global) à la série 5 dates de NDVI et de bandes spectrales, pour RF et SVM.	146
Figure 73 : Evolution de l'indice de Kappa en fonction de l'organisation temporelle et de la composition radiométrique des séries, pour les 2 algorithmes de classification.	147
Figure 74:Précision producteur, précision utilisateur et erreur d'omission et de commission de la meilleure classification par la méthode SVM des 6 formations végétales étudiées.	149
Figure 75: Précision producteur, précision utilisateur et erreur d'omission et de commission de la meilleure classification par la méthode RF des 6 formations végétales étudiées. AFAIRE	150
Figure 76: Matrice de confusion calculée en surfaces (hectares) correspondant à la meilleure classification par RF. Fond vert : surfaces correctement classées. Fond rose : surfaces mal classées supérieures à 500 ha. Gras : surfaces supérieures à 1 500 ha.	151
Figure 77 : Extrait de la carte de référence sur le site d'étude HRS (en haut) et de la classification avec RF RF (en bas) pour les 6 formations végétales étudiées.	152
Figure 78: Cartographie des pixels concordants et non concordants pour SVM et RF.	153
Figure 79: Matrice de confusion calculée en surfaces (hectares, matrices a et d), en pourcentages en lignes (PP et erreur d'omission, matrices b et e) et en pourcentages en colonnes (PU et erreur de commission, matrices c et f) de la meilleure classification par RF des séries temporelles MODIS et des séries d'images DEIMOS.	154
Figure 80 :Comparaison cartographique entre la cartographie forestière de référence (a), la meilleure classification des données DEIMOS obtenue par RF (b), la meilleure classification des données MODIS obtenue par RF (c), la carte des pixels bien et mal classés de la classification b (d), la carte des pixels bien et mal classés de la classification c (e).	156

Liste des tableaux

Tableau 1 : Exemples d'indices de végétation utilisés dans le cadre de l'analyse des milieux forestiers (Lambert, 2014). ρ : réflectance ; RED : bande spectrale dans le rouge ; NIR : bande spectrale dans le proche infrarouge ; SWIR : bande spectrale dans l'infrarouge moyen ; BLUE : bande spectrale dans le bleu ; L : variable d'ajustement.	25
Tableau 2 : Exemple de matrice de confusion, d'après (Stehman, 2009).	37
Tableau 3 : Caractéristiques des données du produit MOD13Q1 utilisées	56
Tableau 4 : Sélection, parmi les données disponibles, des images DEIMOS exploitables pour l'étude du site d'étude HRS.	58
Tableau 5 : Caractéristiques des données de l'IGN utilisées pour constituer la base de données de référence. V1 : version 1 de l'inventaire forestier, V2 : version 2 de l'inventaire forestier.	61
Tableau 6 : MFE50 (Mapa Forestal de España a escala 1 :50.000)	62
Tableau 7 : Mapa Forestal d'Andorra (MFPA)	62
Tableau 8 : Liste des formations végétales et de milieux naturels sans végétation pour le site d'étude MRS.	63
Tableau 9 : Nomenclature retenue pour les classifications.	65
Tableau 10: Placettes des inventaires forestiers France-Espagne.	67
Tableau 11 : Indices décrivant les caractéristiques topographiques et paysagères des strates.	72
Tableau 12: Indicateurs d'évaluation de la qualité de classification.	74
Tableau 13: Valeurs minimales, maximales et écart-type calculés par strate pour les 8 indices paysagers et topographiques.	77
Tableau 14: Evaluation au niveau global de la qualité de classification obtenue avec et sans stratification pour les deux périodes étudiées (indice de Kappa et taux de rejet).	77
Tableau 15: Effet de la stratification sur la précision producteur pour la période 2007-2009.	78
Tableau 16 : Fraction de rejet par rapport au rejet total.	79
Tableau 17 : Corrélations de Pearson (r^2) entre les indices à la strate et les écarts de K et de TR pour la période 2007-2009 (grisé : corrélation significative pour $\alpha=0,01$; (+) : corrélation positive ; (-) : corrélation négative).	81
Tableau 18: Comparaison des résultats de segmentation (dans le cas de l'indice de texture « moment secondaire ») pour les valeurs 15 et 20 du paramètre d'échelle et incidence sur le nombre de "strates critiques".	86
Tableau 19 : Paramètres propres à la méthode de classification Random Forest. En bleu : paramètres dont l'ajustement requiert des tests préalables.	95
Tableau 20 : Définition des taux d'échantillonnage.	96
Tableau 21 : Définition des seuils de taux de classe majoritaire pour la construction du jeu d'entraînement.	97
Tableau 22 : Nombre total d'images composant les 60 séries temporelles. Durée : 1- une année (année 2000) ; 2- deux années (2000-2001) ; 3- trois années (2000-2002).	98
Tableau 23 : Valeurs optimales du taux d'échantillonnage retenues pour les 3 méthodes de classification.	105
Tableau 24 : Valeurs optimales du taux d'échantillonnage et du taux de classe majoritaire retenues pour les 3 algorithmes.	106
Tableau 25 : Composition optimale de la série temporelle de NDVI pour les 3 méthodes de classification.	110

Tableau 26 : Composition optimale de la série temporelle d'EVI et de NDVI pour les 3 algorithmes (CM : classe majoritaire).....	112
Tableau 27 : Configuration optimale pour les 3 algorithmes.	114
Tableau 28 : Comparaison des précisions de classification maximales obtenues pour les 3 méthodes à partir de leur configuration optimale.....	117
Tableau 29: Evolution temporelle de la valeur de l'indice de Kappa, calculé à partir de l'ensemble des pixels classés, pour chaque procédure de classification et pour la période 2000-2014.....	117
Tableau 30 : Evolution temporelle de la valeur de l'indice de Kappa, calculé à partir des placettes, pour chaque procédure de classification et pour la période 2000-2014.	118
Tableau 31 : Amplitude des moyennes et des écarts-types des séries de valeurs de l'indice F-Score, calculée à partir de l'ensemble des pixels classés, pour chaque procédure de classification et pour la période 2000-2014.....	118
Tableau 32 : Proportion de pixels classés correspondant à chaque valeur de fréquence pour la période 2000-2014 et pour chaque algorithme de classification.	120
Tableau 33 : Combinaison des indicateurs fréquence et variabilité.....	123
Tableau 34 : Valeur moyenne par classe des indicateurs de précision (F-score, erreur d'omission et de commission) pour les 3 algorithmes (moyenne des 13 classifications).....	127
Tableau 35 : Matrice de confusion moyenne des 13 classifications produites avec l'algorithme RF pour les séries 3 ans de 2000 à 2014 (valeurs en milliers d'hectares). Valeurs en rouge : surfaces supérieures à 8 000 ha. Les couleurs des groupes de classes sont reprises de la figure précédente.....	128
Tableau 36: nomenclature retenue pour le site d'étude HRS.	135
Tableau 37: variation du taux d'échantillonnage du jeu d'entraînement.	136
Tableau 38 : nombre total d'images composant les 10 séries étudiées.	137
Tableau 39: valeurs par classe de la précision producteur (PP), de la précision utilisateur (PU) et du F-Score pour un taux d'échantillonnage de 1% et pour SVM.	141
Tableau 40 : valeurs par classe de la précision producteur (PP), de la précision utilisateur (PU) et du F-Score pour un taux d'échantillonnage de 7% et pour SVM.	141
Tableau 41: valeurs par classe de la précision producteur (PP), de la précision utilisateur (PU) et du F-Score pour un taux d'échantillonnage de 4,5% et pour RF.	141
Tableau 42: écarts de PP et de PU observés pour SVM et pour chaque classe entre les différents nombres de dates. En gras et noir : gains supérieurs ou égaux à 15%. En gras et rouge : dégradations.	144
Tableau 43 : écarts de PP et de PU observés pour RF et pour chaque classe entre les différents nombres de dates. En gras et noir : gains supérieurs ou égaux à 15%. En gras et rouge : dégradations.	144
Tableau 44 : configuration optimale de la série d'images DEIMOS pour les 2 algorithmes de classification.....	147
Tableau 45 : matrice de confusion comparant la carte de stabilité temporelle établie dans le chapitre précédent à la résolution spatiale MODIS (lignes) à la carte des pixels bien et mal classés par rapport à la référence établie à la résolution spatiale DEIMOS.....	157
Tableau 46 : Proportion de pixels concordants et non concordants dans la population de pixels DEIMOS.....	160
Tableau 47 : Ecart de PP et de PU liés au changement de résolution spatiale et observés pour chaque classe. Gras : gain de PP ou de PU.....	161

Introduction générale

Couvrant environ 40% de la surface terrestre, la végétation forestière est une composante du milieu naturel particulièrement suivie et étudiée (Westoby, 1989). La forêt a une triple fonction (Franklin, 2001 ; Kerr et Ostrovsky, 2003) : une fonction économique, par la production et la commercialisation du bois, une fonction environnementale, car elle constitue un réservoir de biodiversité, un ensemble complexe d'écosystèmes à préserver et un puits d'absorption de CO₂, qui permet de réguler l'effet des gaz à effet de serre, et une fonction sociale, car elle fournit des aménités.

Or, dans certaines parties du globe, la couverture forestière a tendance à régresser ou se modifier qualitativement. Elle est également particulièrement sensible aux effets du changement climatique et aux événements brutaux tels que les tempêtes et les épisodes de sécheresse (Cleland et al., 2007 ; Lindner et al., 2010).

La forêt constitue, à ce titre, une ressource à préserver. Le suivi de l'état de santé des forêts, la gestion et l'entretien de l'ensemble des ressources forestières représentent donc des enjeux importants. Ces activités, très anciennes d'un point de vue historique et plus que jamais d'actualité, reposent sur la cartographie de la végétation forestière (Franklin, 2001). Les inventaires forestiers, réalisés à partir de relevés de terrain et de méthodes statistiques sont longtemps restés l'unique source d'information pour cartographier précisément la forêt. Dans ce contexte, l'étendue géographique des documents produits a longtemps été limitée à des secteurs de quelques milliers d'hectares. Cependant, pour répondre aux multiples besoins actuels de gestion de la ressource forestière et d'analyse de changement du couvert arboré, la cartographie des forêts doit pouvoir être réalisée à différentes échelles (locale, régionale, nationale ou globale) et à différents pas de temps (à une date donnée, sur plusieurs années, sur plusieurs décennies).

La mise à disposition de nombreuses données de télédétection spatiale a permis de répondre partiellement à ce besoin (Cihlar, 2000 ; Stehman et al., 2011). L'exploitation d'images satellitaires, dont les résolutions spatiale et temporelle sont de plus en plus élevées, a permis de produire des cartes du couvert forestier pour de vastes étendues, avec des précisions dans la description de la composition très variables (Nagendra, 2001 ; Ohmann et al., 2014). L'apparition des capteurs à moyenne résolution spatiale, caractérisés par une haute répétitivité temporelle avec une acquisition par jour, permet de disposer d'un grand nombre d'informations. Grâce à une acquisition continue et régulière depuis maintenant de nombreuses années, il est possible de constituer des séries temporelles sur de vastes étendues géographiques et de disposer de données d'archive (depuis 2000 dans le cas de MODIS). Les capteurs à haute résolution spatiale ont une résolution temporelle plus faible et il est donc plus difficile de disposer d'un grand nombre d'images exploitables sur une année. Elles sont ainsi plus adaptées pour une cartographie à une échelle locale et pour fournir des informations dont les précisions géographique et thématique sont nécessaires aux besoins de gestion forestière.

On peut considérer que les produits issus de la télédétection permettent de compléter efficacement les relevés de terrain (Reed et al., 1994 ; Studer et al., 2007). En dépit de cette avancée, l'ensemble des besoins cartographiques liés au suivi et la gestion de la végétation forestière ne sont pas totalement satisfaits. Il est ainsi nécessaire de disposer de cartes plus détaillées décrivant la composition en essences d'un territoire régional. L'obtention de tels documents à partir de la classification d'images de télédétection reste complexe et difficile. La réponse à ce besoin cartographique suppose de bien exploiter les caractéristiques spectrales de la végétation et de maîtriser toutes les étapes définissant la procédure de classification des images.

Couramment employée pour cartographier la forêt, la classification supervisée par pixel d'une série temporelle d'images de télédétection constitue l'une des méthodes actuelles les plus efficaces pour distinguer les essences. Une telle procédure repose sur un ensemble de choix méthodologiques ayant une influence sur la qualité des résultats obtenus (Dengsheng et al., 2011).

Ces choix reposent sur un ensemble d'éléments essentiels : la compréhension du besoin cartographique, la connaissance des caractéristiques du site d'étude, la définition de la nomenclature et le niveau de précision attendu dans la distinction des essences la qualité des données de référence. De manière évidente, le choix des images à traiter et l'organisation de la série temporelle sont cruciaux et sont avant tout liés aux caractéristiques spectrales et phénologiques de la végétation. Cette dernière se caractérise sur le plan spectral par une absorption importante des longueurs d'onde dans le rouge et une forte réflectance dans le domaine du proche infrarouge. Ces propriétés sont systématiquement exploitées lors de la classification des images, en utilisant directement les bandes spectrales, ou des indices de végétation tels que l'EVI et le NDVI dérivés de ces dernières. La valeur des indices de végétation, qui sont corrélés à l'activité photosynthétique de la végétation (Pettorelli et al., 2005), évolue avec le temps. Cette évolution sur une année traduit le cycle saisonnier d'activité végétale spécifique à chaque type de végétation. Les séries temporelles d'images de télédétection permettent ainsi de distinguer les essences selon leur profil phénologique et d'obtenir ainsi des cartes forestières plus précises sur le plan thématique.

Toutefois, la précision des classifications reste insuffisante dès lors qu'on souhaite réaliser des cartes détaillées de la composition en essences d'un territoire à une échelle régionale. Plusieurs limites sont à l'origine de cette situation : l'effet de la résolution spatiale des données d'entrée qui entraîne la présence de pixels mixtes, les effets de la similarité inter-classes et de la variabilité intra-classe des réponses spectrales des essences forestières, ou encore l'effet des imprécisions et erreurs contenues dans les données de référence (Boyd et Foody, 2011 ; Colditz et al., 2011 ; Foody, 2010 ; Xie et al., 2008).

L'objectif principal de cette thèse est d'améliorer la procédure de classification supervisée d'une série temporelle afin de produire des cartes à l'échelle régionale détaillant la composition en essences de la végétation forestière. Il peut être décliné en un objectif thématique et un objectif méthodologique. L'objectif thématique consiste à identifier par télédétection les peuplements purs ou en mélange d'essences forestières sur un territoire de vaste étendue. L'objectif méthodologique consiste à définir la configuration optimale de la procédure de classification supervisée permettant d'obtenir les meilleurs résultats.

Cette thèse est structurée en 5 chapitres :

- Le premier chapitre dresse un état de l'art sur la cartographie de la végétation forestière à partir de séries d'images de télédétection, en se focalisant sur la procédure de classification supervisée d'images de télédétection. Les questions relatives au choix du site d'étude, aux données d'entrée ainsi que la définition de la nomenclature, qui sont stratégiques pour la cartographie forestière, sont analysées en détail. La démarche de recherche développée au cours de la thèse est présentée dans ce chapitre ;
- Le deuxième chapitre décrit de façon détaillée le site d'étude et les données d'entrée utilisées ;
- Le troisième chapitre porte sur l'évaluation de l'apport de la stratification du site d'étude pour améliorer les résultats de classification d'une série temporelle d'images à moyenne résolution spatiale, en l'occurrence des images MODIS ;
- Le quatrième chapitre porte sur l'évaluation de l'influence de l'organisation de la série temporelle d'images à moyenne résolution spatiale et du choix de l'algorithme de

classification sur la qualité des résultats obtenus. Cette évaluation est effectuée pour trois algorithmes, en faisant varier les données d'entrée, tant au niveau de la série temporelle elle-même (variables dérivées de la série, organisation de la série) que des données ancillaires utilisées ;

- Le cinquième et dernier chapitre porte sur l'évaluation de l'apport du changement de résolution spatiale des images composant la série temporelle utilisée sur les résultats de la classification, notamment pour améliorer la distinction de mélanges d'essences forestières. Compte tenu des résultats du chapitre précédent, cette évaluation est effectuée pour deux algorithmes, en faisant varier les données d'entrée, tant au niveau de la série temporelle elle-même (variables dérivées de la série, organisation de la série) que des données ancillaires utilisées.

Ce travail de thèse a été initié dans le cadre d'un axe de recherche de l'Observatoire Pyrénéen du Changement Climatique (OPCC et CTP) et du Programme Opérationnel de Coopération Territoriale Espagne-France-Andorre (POCTEFA). Les travaux réalisés s'intègrent également dans le cadre des productions de l'UMR DYNAFOR (INRA), auquel l'équipe de télédétection de l'EI-Purpan est rattachée, plus particulièrement dans l'axe RAMSSES : « Recherche en Analyse et Modélisation de Systèmes Socio-Ecologiques Spatialisées ».

Chapitre 1 : Contexte, démarche et objectifs de la thèse

La cartographie du couvert végétal est un outil essentiel à la gestion et au suivi des milieux naturels et en particulier de la forêt. La cartographie forestière doit répondre à de multiples besoins, tant à une échelle globale qu'à une échelle locale, tels que la représentation de la couverture forestière planétaire pour en étudier l'évolution ou la caractérisation de peuplements forestiers à la parcelle. Ces besoins conditionnent le niveau de précision thématique et cartographique attendue par les utilisateurs (Ohmann et al., 2014). Le suivi du couvert forestier sur l'ensemble du globe permet d'évaluer les tendances générales de son évolution en tant que ressource planétaire, par exemple en estimant des pertes de surface ou sa biomasse (Giri et al., 2013 ; Hansen et al., 2013 ; Justice et al., 1998 ; Kim et al., 2014 ; Shimada et al., 2014 ; Wang et al., 2014). A cette échelle, l'usage d'une nomenclature forestière détaillée n'est pas nécessaire. En revanche, pour répondre à des besoins de gestion et d'inventaire à une échelle locale ou régionale, une cartographie détaillée des surfaces forestières avec une connaissance précise de leur composition en essences est indispensable.

La réalisation de telles cartes implique généralement de combiner des images satellitaires avec des relevés de terrain (Ohmann et al., 2014) ou des observations faites à partir de photographies aériennes (Esseen et al., 2006 ; Lister et al., 2014 ; Thompson et al., 2007 ; Welch et al., 2002). Sans télédétection, réaliser une cartographie exhaustive et détaillée de la végétation à une échelle régionale est une tâche complexe et difficilement réalisable (Foody et al., 1997). Les données de télédétection sont exploitées dans bien des cas, et en particulier pour couvrir des territoires vastes ou difficiles d'accès, alors que le recours à des relevés terrain s'avère trop coûteux, voire irréalisable. La mise à disposition progressive de produits satellitaires a permis d'envisager le développement de méthodes de cartographie alternatives et complémentaires aux approches traditionnelles d'inventaires et de relevés de terrain (Boyd et Danson, 2005 ; Cihlar, 2000 ; García-Mora et al., 2011 ; Stehman et al., 2011). Toutefois, les images satellitaires n'ont pas encore permis de produire des cartes forestières avec une nomenclature détaillée en raison de la difficulté à atteindre le niveau de précision requis (Kuemmerle et al., 2006 ; Stehman et al., 2011). Ce besoin s'avère pourtant fondamental pour la gestion forestière.

Le lancement successif de différents satellites dédiés à l'étude des ressources terrestres a progressivement favorisé le développement de méthodes de traitement d'images visant à identifier et caractériser la végétation, la plupart reposant sur la classification d'indices de végétation calculés à partir des bandes spectrales. Lorsqu'il ne s'agit pas de séparer des surfaces de comportements spectraux très éloignés (zones urbaines *versus* végétation par exemple) mais de distinguer différents types de formations au sein d'une même surface végétalisée, une approche de classification d'une image satellitaire exclusivement basée sur la signature spectrale des espèces à une date donnée est le plus souvent insuffisante (Boyd et Danson, 2005 ; Carrão et al., 2007 ; Dymond et al., 2002 ; Evans et Geerken, 2006 ; Redo et Millington, 2011 ; Xie et al., 2008). Face à ce constat, la prise en compte de la dimension temporelle à travers l'usage de séries temporelles d'images s'est progressivement imposée afin d'améliorer la reconnaissance des formations forestières. Les espèces sont alors discriminées selon la variabilité de leur réponse spectrale au cours du temps, celle-ci étant liée à leur comportement phénologique (Clark et al., 2010 ; Pettorelli et al., 2005 ; Xie et al., 2008). Ainsi, l'analyse des signatures temporelles, qui traduisent le comportement annuel ou saisonnier des essences, permet de distinguer les principales espèces forestières.

Ainsi, en s'appuyant sur l'analyse de l'évolution du comportement spectral de la végétation forestière, il est possible d'envisager la cartographie des différentes espèces qui la composent. Pour cela, il est nécessaire d'optimiser toutes les étapes de la procédure de classification des séries de données de télédétection.

1 Les caractéristiques spectrales et temporelles de la végétation

La végétation présente des caractéristiques spectrales bien spécifiques, liées à son activité photosynthétique (figure 1). Dans le domaine optique, elles se manifestent, principalement sous la forme d'une forte réflectance dans le domaine du proche infrarouge (760 nm à 1 500 nm) conjuguée à une forte absorption dans le domaine du rouge (640 nm à 720 nm) et dans le domaine de l'infrarouge moyen (1 400 et 1700 nm).

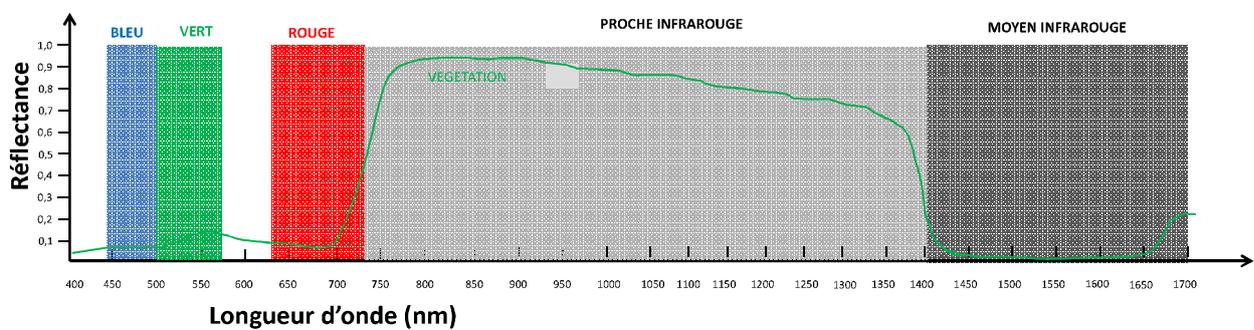


Figure 1 : Profil spectral d'une végétation active.

Ces caractéristiques spectrales sont variables selon l'espèce et selon l'évolution de son activité durant le cycle saisonnier annuel. De nombreux travaux visant à caractériser et à cartographier la composition de la végétation se basent ainsi sur la distinction des espèces d'après leur phénologie. La dimension spectrale et temporelle des données d'entrée utilisées pour la classification est alors adaptée de façon à restituer ces caractéristiques phénologiques.

L'exploitation étendue de la dimension spectrale des données pour cartographier la végétation fait partie des sujets les plus étudiés actuellement. Cette approche consiste à classer des données hyperspectrales. Par opposition à l'imagerie multispectrale, les images hyperspectrales ne se composent pas d'une douzaine mais d'une centaine –voire plus– de bandes spectrales. Par exemple, le capteur AVIRIS réalise des acquisitions de 4 m à 20 m de résolution spatiale sur 224 bandes spectrales dans un domaine de longueur d'ondes allant de 400 à 2 500 nm (Xie et al., 2008). La quantité d'information ainsi traitée est très importante et est particulièrement adaptée à la caractérisation de mélanges et gradients complexes de végétation (Dalponte et al., 2012 ; Zhu et Liu, 2014).

Le calcul d'un indice de végétation à partir des images de télédétection permet de combiner les réflectances spectrales caractéristiques du couvert végétal, notamment celles qui sont liées à son activité photosynthétique. De nombreux indices ont été étudiés et utilisés pour classer des données de télédétection (voir les exemples présentés dans le tableau 1). Les deux indices de végétation les plus étudiés sont le NDVI (Normalized Difference Vegetation Index) et l'EVI (Enhanced Vegetation Index).

Le NDVI correspond à l'écart entre les réflectances dans le rouge et le proche infrarouge, normalisé par la somme de ces deux réflectances (Pettorelli et al., 2005 ; Rouse et al., 1973 ; Tucker et al., 1985). Ses valeurs sont théoriquement comprises entre -1 et +1, mais dans la pratique on observe une variation entre 0,1 et 0,7. Le NDVI est corrélé à la productivité primaire nette de la végétation et est sensible à l'activité chlorophyllienne (Huete et al., 2002 ; Pettorelli et al., 2005). Plus l'activité de la végétation est importante, plus la valeur du NDVI est élevée (Goward, 1985). C'est l'indice le plus couramment utilisé pour cartographier le couvert végétal avec une approche temporelle (DeFries et al., 1995 ; Tucker et Sellers, 1986). Chaque formation est caractérisée par un profil temporel de NDVI (nommé communément profil phénologique) qui lui est spécifique et permet de la distinguer des autres.

L'évolution saisonnière de la valeur du NDVI peut ainsi être reliée aux différentes phases de cette activité durant un cycle annuel. L'interprétation des variations intra-annuelles de NDVI ou cycle saisonnier repose sur la notion de phénologie. Par phénologie, on entend la répartition dans le temps des étapes de croissance et de développement des plantes qui se produisent de manière cyclique sous l'influence des facteurs climatiques. Quand la phénologie est étudiée par télédétection, on parle de phénologie de surface (*Land Surface Phenology* en anglais) pour faire la distinction avec les analyses de phénologie par l'observation au sol des individus d'une espèce donnée (Reed et al., 2009). Sur les images satellitaires, l'information est agrégée car elle traduit la réponse d'un couvert végétal, souvent hétérogène, correspondant à la surface couverte par le pixel. L'acquisition de données régulières de NDVI rend possible le suivi des changements cycliques de la réponse du couvert, qui sont généralement assimilés à des stades phénologiques et qui se produisent de façon relativement prévisible et reproductible (Lambert, 2014).

Le profil annuel de NDVI des essences forestières varie fortement selon leur phénologie (Chéret et Denux, 2011 ; Chéret et Denux, 2007). Pour une espèce atlantique telle que le hêtre, les phases de croissance printanière et de sénescence automnale sont ainsi très marquées (figure 2). Dans le cas d'une espèce adaptée au climat méditerranéen telle que le pin d'Alep, l'évolution de l'activité et les caractéristiques du cycle annuel sont différentes.

Tableau 1 : Exemples d'indices de végétation utilisés dans le cadre de l'analyse des milieux forestiers (Lambert, 2014). ρ : réflectance ; RED : bande spectrale dans le rouge ; NIR : bande spectrale dans le proche infrarouge ; SWIR : bande spectrale dans l'infrarouge moyen ; BLUE : bande spectrale dans le bleu ; L : variable d'ajustement.

Nom de l'indice	Acronyme	Equation	Référence
Normalized Difference Vegetation Index	NDVI	$\frac{\rho_{NIR} - \rho_{RED}}{\rho_{NIR} + \rho_{RED}}$	(Rouse et al., 1973)
Enhanced Vegetation Index	EVI	$2,5 \frac{\rho_{NIR} - \rho_{RED}}{\rho_{NIR} + 6\rho_{RED} - 7,5\rho_{BLUE} + 1}$	(Huete et al., 1997)
Soil Adjusted Vegetation Index	SAVI	$\frac{(\rho_{NIR} - \rho_{RED})(1 + L)}{(\rho_{NIR} + \rho_{RED} + L)}$	(Qi et al., 1994)
Normalized Difference Infrared Index	NDII	$\frac{\rho_{NIR} - \rho_{SWIR}}{\rho_{NIR} + \rho_{SWIR}}$	(Toomey et Vierling, 2005)
Infrared Ratio Index	IRI	$\frac{\rho_{NIR}}{\rho_{SWIR}}$	(Toomey et Vierling, 2005)

Le profil annuel de NDVI constitue ainsi une donnée très efficace pour distinguer différentes espèces végétales et notamment les essences forestières (Justice et al., 1985). Toutefois, le NDVI est sensible aux effets du sol sous-jacent et à l'atmosphère et d'autres indices permettant de s'affranchir en partie de ces effets sont utilisés pour cartographier la végétation (Baret et Guyot, 1991 ; Henebry, 1993 ; Huete et al., 1985).

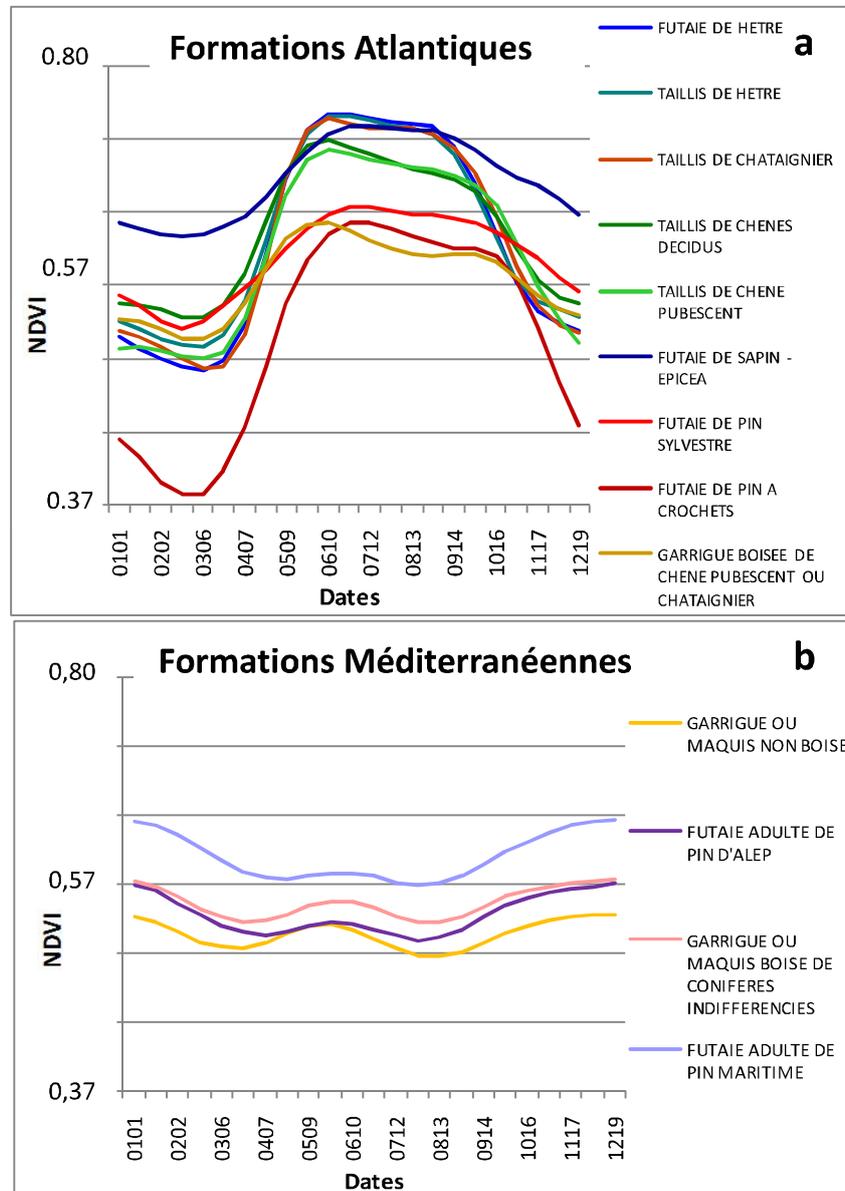


Figure 2 : Profils annuels de NDVI de formations forestières atlantiques (a) et de formations méditerranéennes (b). Source : (Chéret et Denux, 2011)

L'indice EVI (Huete et al., 1997) intègre dans son calcul la réflectance dans le domaine du bleu (440 nm à 490 nm), ce qui permet de tenir compte des effets des aérosols sur les réflectances dans le rouge (Huete et al., 2002 ; Justice et al., 1998). Cet indice est davantage sensible aux variations structurelles de la canopée que le NDVI (Boyd et Danson, 2005 ; Gao et Mas, 2008 ; Justice et al., 1998).

De nombreuses études de la végétation et travaux de classification utilisent le NDVI (Goward, 1985 ; Townshend et al., 1994 ; Tucker et Sellers, 1986) et l'EVI (Bagan et al., 2005 ; Gao et Mas, 2008 ; Zhang et al., 2006 ; Zhang et al., 2008 ; Zhang, 2004). Les apports de ces deux indices sont considérés

comme complémentaires pour l'étude de la végétation à l'échelle globale (Gao et Mas, 2008 ; Huete et al., 2002 ; Justice et al., 1998).

Une telle approche suppose toutefois de disposer d'images acquises à un pas de temps suffisamment fin et régulier. C'est le cas des images fournies par les capteurs à haute répétitivité temporelle et à moyenne ou basse résolution spatiale tels que SPOT-VEGETATION, NOAA-AVHRR, ENVISAT-MERIS et TERRA-MODIS.

Selon la disponibilité des données exploitables, plusieurs approches sont possibles pour cartographier la végétation. L'une consiste à exploiter des images acquises à différentes périodes de l'année. Les travaux basés sur cette approche peuvent permettre de distinguer, par « contraste », les essences caduques des essences sempervirentes, ainsi que plusieurs essences de feuillus (Goetz et al., 1999 ; Krahwinkler et Rossmann, 2013). Les séries d'images ainsi constituées sont qualifiées de séries multi-dates. L'approche employée se basant sur une information discontinue, elle ne peut reposer sur la phénologie de la végétation dans sa globalité.

Avec le développement des capteurs à haute répétitivité temporelle et l'augmentation de la quantité de données exploitables, de nombreux travaux se basent sur une approche temporelle, en utilisant les informations fournies de manière continue et régulière. Les séries d'images ainsi construites sont qualifiées de séries multi-temporelles ou séries temporelles. Elles peuvent également avoir une portée à long terme, c'est-à-dire couvrir une durée de plusieurs années, en allant jusqu'à la notion de séries hyper-temporelles (Ali et al., 2013). Il est ainsi possible de développer des approches de traitement des données reposant sur l'ensemble du cycle phénologique de la végétation pour obtenir une distinction plus fine des essences (Hansen et al., 2000 ; Knight et al., 2006). De très nombreux travaux portant sur l'étude et la cartographie de la végétation sont ainsi basés sur la classification de séries multi-temporelles de NDVI (Boyd et Foody, 2011 ; García-Mora et al., 2011 ; Jia et al., 2014b ; Pettoelli et al., 2005). Elles sont très utilisées pour étudier la dynamique de la végétation ou distinguer différents types forestiers ou phénologiques, soit à partir du cycle annuel complet de NDVI, soit à partir de « métriques phénologiques » (Reed et al., 1994), décrivant une partie de ce cycle, tels que le maximum ou l'amplitude du profil de NDVI (García-Mora et al., 2011 ; Heiskanen et Kivinen, 2008 ; Jia et al., 2014a).

2 La classification de la végétation

2.1 La classification d'images de télédétection

La classification d'images de télédétection est un procédé consistant à attribuer à chaque unité spatiale constituant le site d'étude (pixel, objet) une classe en se basant sur sa signature (Xie et al., 2008). Les classes correspondent à des thèmes précis tels que des catégories d'occupation des sols ou des peuplements forestiers (Tso et Mather, 2009). La signature d'un pixel est basée sur sa signature spectrale, tandis que celle d'un objet, est basée sur ses caractéristiques (spectrales, texturales, positionnement par rapport aux objets voisins...). Les approches de classification sont nombreuses. Cette diversité est née du besoin continu d'améliorer la performance du procédé de classification pour obtenir des cartes de plus en plus précises.

Les approches peuvent différer par le type d'unité spatiale à laquelle est appliquée la classification (Lu et Weng, 2007). L'approche la plus traditionnellement employée consiste à considérer comme unité spatiale le pixel des images à traiter. Cette approche est dénommée classification par pixel et représente l'approche la plus fréquemment employée pour cartographier la végétation.

L'unité spatiale peut également correspondre à une entité géographique résultant de la fusion d'un groupe de pixels possédant des caractéristiques homogènes (spectrales, texturales...). Cette opération de fusion est nommée segmentation. Il est notamment possible, par segmentation d'images, de fusionner des pixels en objets correspondant aux peuplements forestiers (Dorren et al., 2003 ; Woodcock et Harward, 1992). La classification qui est alors appliquée à ces segments (ou objets) et non à des pixels est une classification orientée objet.

Enfin, l'unité spatiale peut être de taille inférieure au pixel : on considère alors qu'il est possible de lui attribuer plusieurs classes. Dans ce cas spécifique, la correspondance établie entre l'objet et les classes n'est pas de type 1 à 1, mais 1 à n. On parle de classification « floue ». Par opposition, la classification traditionnelle consiste à attribuer directement une classe unique à chaque objet. La classification floue repose sur un principe probabiliste, comme le maximum de vraisemblance, mais consiste à évaluer plusieurs probabilités d'appartenance au sein d'un unique pixel (Xie et al., 2008) avant d'attribuer le pixel à une classe donnée. Cette approche, déjà évoquée précédemment, permet de traiter la problématique des pixels mixtes et se révèle particulièrement adaptée pour traiter les gradients de végétation, qui peuvent être mal classés en appliquant une approche de classification non floue (Hill et al., 2007). En ce sens, elle est étudiée à titre d'élément d'amélioration de la classification.

Parmi les approches de classification directe (non floue) par pixel, on distingue plusieurs méthodes relatives aux modes d'attribution des classes.

Une première distinction importante porte sur la définition des classes en elles-mêmes. Dans certains cas, on dispose d'une connaissance préalable du territoire à classer, et notamment d'un savoir expert. Les classes à cartographier sont ainsi prédéfinies sur le plan thématique (composition en essences par exemple) et spatial (délimitation). Il est possible d'intégrer cette information dans le processus de classification, sous la forme :

- d'une nomenclature définissant les classes et leur sens thématique,
- d'un jeu d'entraînement, composé d'échantillons dont la signature est représentative de ces classes.

Une telle approche porte la dénomination de classification supervisée (Lu et Weng, 2007 ; Tso et Mather, 2009). Lorsqu'aucune définition préalable des classes n'est utilisée, par opposition, la classification est dite non supervisée.

La deuxième distinction porte sur les règles de décision utilisées pour l'attribution des classes, c'est-à-dire l'algorithme de classification. On distingue ainsi les algorithmes paramétriques et non paramétriques (Hubert-Moy et al., 2001). Les algorithmes paramétriques de classification reposent sur l'hypothèse d'une distribution statistique gaussienne des signatures représentatives d'une classe donnée. Par définition, ils ne peuvent donc s'appliquer que dans le cadre d'une classification supervisée par pixel et ne sont performants que lorsque la répartition des pixels au sein d'une classe répond à une distribution gaussienne. Les paramètres statistiques (vecteur moyen et covariance) de chaque classe sont calculés à partir du jeu d'entraînement et considérés comme représentatifs pour la totalité des pixels à classer. Par opposition, les algorithmes non paramétriques ne sont basés sur aucun prérequis relatif à la distribution des signatures représentatives d'une classe (Lu et Weng, 2007). Plus souples, ils présentent donc un intérêt certain dans le cas de classes pour lesquelles la distribution statistique des pixels ne répond pas à une loi normale.

2.2 La procédure de classification supervisée

La mise en œuvre d'une procédure de classification supervisée comporte plusieurs étapes, résultant d'un ensemble de choix méthodologiques et techniques (Dengsheng et al., 2011 ; Lu et Weng, 2007). On s'intéresse ici au cas d'une classification non floue (directe) par pixel. Les différentes étapes de la procédure de classification (figure 3) concernent tout d'abord l'expression du besoin cartographique et la connaissance des principales caractéristiques (pédo-morpho-climatiques) du site à cartographier, puis l'élaboration de la nomenclature avec la définition des classes qui vont servir à l'entraînement de la classification, ensuite du choix, de la collecte et de l'organisation des données d'entrée, de la constitution des signatures spectrales et temporelles des classes, et enfin des différentes phases de traitement de classification en fonction du choix de l'algorithme utilisé. La dernière étape est l'évaluation de la qualité qui repose sur l'utilisation possible de différents indicateurs et qui généralement conduit à retravailler sur l'amélioration des signatures des classes et parfois à ajuster la nomenclature.

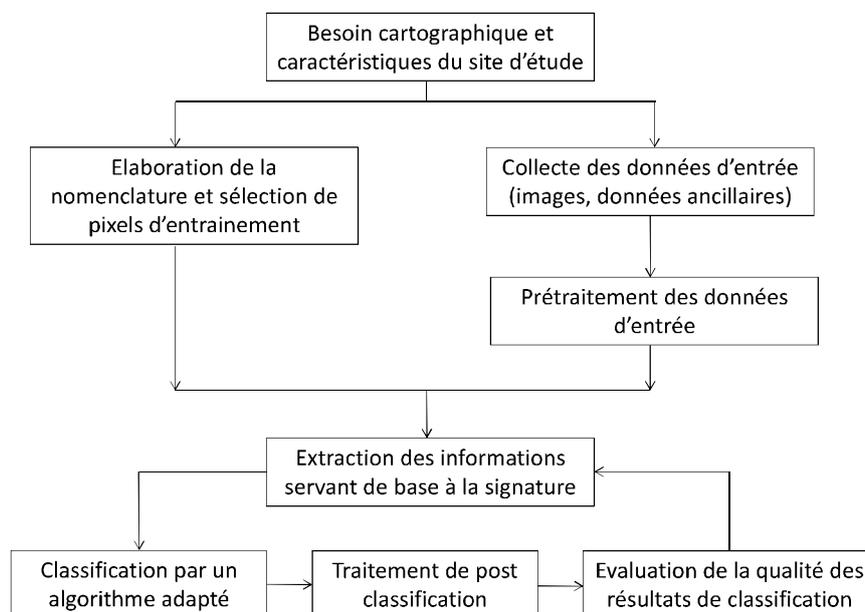


Figure 3 : Etapes fondamentales d'une procédure de classification supervisée « directe » par pixel, d'après (Dengsheng et al., 2011).

2.2.1 *Définition du besoin cartographique et des caractéristiques du site d'étude*

La conception de la démarche à appliquer est fortement conditionnée par les objectifs de recherche auxquels répond la classification, ainsi que par les caractéristiques du site d'étude (Dengsheng et al., 2011). Préalablement à la définition de la démarche de classification, le niveau de précision thématique souhaitée ainsi que l'échelle d'analyse de l'étude doivent impérativement être identifiés.

La réflexion quant au niveau de précision thématique inclut l'identification des catégories d'occupation du sol ainsi que le niveau de détail de la cartographie produite. Si on prend l'exemple de la végétation, il est possible de la considérer d'une façon globale (types de forêts ou de milieux végétalisés naturels, par opposition aux cultures), ou de la décrire avec plus ou moins de finesse (distinction des grands groupes d'essences forestières du type résineux/feuillus ; distinction d'essences forestières en peuplements purs ou en mélange) (Boyd et Danson, 2005). A cette réflexion peuvent s'intégrer, lorsqu'ils existent, une pré-connaissance ou un savoir expert de ces catégories d'occupation des sols, qui conduiront à la construction d'une nomenclature en vue d'une classification supervisée.

Les caractéristiques du site d'étude conditionnent la quantité et la nature des données de télédétection, notamment des images satellitaires, qui seront exploitées en entrée de classification. Une cartographie à l'échelle locale ne nécessite pas la même quantité de données qu'une cartographie à l'échelle régionale (Cihlar, 2000). Dans ce contexte, les études de cartographie de la végétation ou de l'occupation des sols sont fréquemment contraintes par le coût, la disponibilité et le caractère exploitable des images. Le choix de l'étendue géographique influence aussi la résolution spatiale de ces images.

Dans le cas d'un site d'étude de grande étendue, il est possible de ne pas le traiter d'un seul tenant. On peut avoir recours à une stratification du site d'étude (Cai et al., 2011 ; Stehman, 2009). Cette méthode consiste à le découper en sous-régions et à appliquer la classification à chacune de ces sous-régions et non au site d'étude toute entier. Une telle méthode peut contribuer à réduire la variabilité spatiale intra-classe des signatures temporelles des formations que l'on cherche à identifier (Delincé, 2002 ; Gallego et Stibig, 2013 ; Gertner et al., 2007 ; Stehman et al., 2011). Dans le cas de grands territoires hétérogènes, il est fréquent d'avoir recours à un découpage en zones bioclimatiques (Beguería et al., 2007 ; Edwards Jr et al., 1998) selon des critères d'homogénéité du paysage, du sol, de la végétation et des conditions climatiques (Broich et al., 2009 ; Congalton et al., 2002 ; Edwards Jr et al., 1998 ; Stehman et al., 2011). Le procédé s'avère adapté, car la distribution spatiale de la végétation est fonction en grande partie de ces critères (Cai et al., 2011). La précision globale de la classification (overall accuracy) peut être améliorée de 10 à 15 % grâce à l'utilisation d'une stratification (Haralick et al., 1973). La délimitation de strates sur un territoire donné peut être basée sur des cartes existantes dont la réalisation dépend en premier lieu de la disponibilité des données thématiques nécessaires (Beguería et al., 2007). Toutefois, une approche de type expert est souvent nécessaire pour ajuster les limites des cartes existantes au contenu des images (Beguería et al., 2007). La mise en œuvre d'une stratification s'avère ainsi complexe et longue à mettre en œuvre et, dans tous les cas, difficilement transposable d'un territoire à un autre.

2.2.2 *Elaboration de la nomenclature et sélection des pixels d'entraînement et de validation*

Les données de référence sont organisées en classes grâce à une nomenclature à laquelle sont associés des pixels jugés représentatifs de chaque classe ou pixels échantillons constituant le jeu d'entraînement et de validation de la classification.

Une nomenclature adaptée et un nombre suffisant de pixels échantillons sont un pré-requis indispensable à une classification supervisée efficace (Lu et Weng, 2007). La nomenclature doit être informative, exhaustive et décomposable en classes indépendantes (Cingolani et al., 2004 ; Hubert-Moy et al., 2001).

Deux facteurs sont particulièrement importants pour la définition des classes (Cingolani et al., 2004) :

- une juste définition de leur hiérarchie, adaptée au territoire étudié,
- l'obtention de classes discrètes et discernables sur les images de télédétection choisies.

Ces caractéristiques sont particulièrement délicates à réunir dans le cas d'images à moyenne résolution spatiale (Lu et Weng, 2007). Il est établi que toute nomenclature mal définie ou mal adaptée aux données de télédétection à traiter engendre une perte de précision notable des résultats de classification (Broich et al., 2009 ; Foody, 2002 ; Foody et al., 1997 ; Giri et al., 2013).

Le jeu d'entraînement et de validation doit fournir les informations nécessaires à la classification supervisée et donc concilier un dimensionnement adapté et une très bonne représentativité des classes. En particulier, il est établi qu'un nombre minimal de pixels doit être atteint pour garantir un bon fonctionnement de la classification supervisée (Chen et Stow, 2002 ; Hubert-Moy et al., 2001 ; Jackson et Landgrebe, 2001). En-dessous d'un seuil critique, quel que soit l'algorithme de classification utilisé, les pixels sont trop peu nombreux pour garantir la représentativité de la classe concernée et ce dernier ne peut l'attribuer correctement (Hughes, 1968). Ce phénomène, dit de Hughes, est lié à la quantité de variables composant les données d'entrée : plus ces dernières sont nombreuses, plus le nombre minimal de pixels par classe doit être élevé pour garantir l'efficacité de la classification (Kurtz, 2009). Une attention particulière doit donc être portée à ce phénomène lorsqu'on traite des séries multitemporelles. Certaines études préconisent ainsi d'entraîner un nombre minimal de pixels par classe correspondant à 10 à 30 fois le nombre de variables des données d'entrée (Foody et al., 2006).

L'influence du dimensionnement du jeu d'entraînement sur la précision des résultats de classification a fait l'objet de nombreux travaux (Foody et Mathur, 2006 ; Foody et al., 2006 ; Stehman, 1996). Ces derniers ont établi que, lorsque le dimensionnement minimal était atteint, plus le nombre de pixels d'entraînement était important, meilleurs étaient les résultats (Foody et Mathur, 2004). Théoriquement, le jeu d'entraînement idéal devrait donc être composé du nombre de pixels le plus important possible. D'autres travaux ont néanmoins démontré que le dimensionnement optimal du jeu d'entraînement était différent d'un algorithme de classification à l'autre (Foody et Mathur, 2006 ; Foody et al., 2006). Le mode de sélection des pixels pour construire le jeu d'entraînement consiste à sélectionner une partie des pixels à classer pour en déduire l'estimation des caractéristiques de la population entière de ces pixels (Rodes et al., 2012). On considère ainsi que les pixels sélectionnés sont représentatifs de cette population. La méthode d'échantillonnage a une grande influence sur les résultats obtenus (Congalton, 1991 ; Stehman et Czaplewski, 1998).

Des travaux ont identifié les critères à satisfaire pour construire le meilleur jeu d'entraînement possible (Carrão et al., 2008 ; Hammond et Verbyla, 1996) :

- la sélection de pixels correspondant à une occupation du sol « pure » par rapport à la classe qu'ils représentent,
- la sélection de pixels la plus étendue possible au sein du territoire étudié, pour prendre en compte de potentielles différences locales et pour éviter les corrélations géographiques liées à des unités spatiales adjacentes,
- la sélection de pixels dans des zones dont on sait qu'elles n'ont pas subi de changements brutaux d'occupation des sols.

Les méthodes de sélection préconisées sont de type probabiliste (Stehman et Czaplewski, 1998), les plus couramment utilisées étant la sélection aléatoire, systématique ou stratifiée. Différentes méthodes de sélection amènent à des classifications différentes. Leur influence est d'autant plus marquée pour des images à haute résolution spatiale (Chen et Stow, 2002).

2.2.3 Collecte des données d'entrée

Avec la progression technique importante que connaissent les capteurs depuis plusieurs décennies, les images satellites exploitables et disponibles sont de plus en plus nombreuses. Elles sont également très variées en termes de résolution spectrale, spatiale et temporelle (Atkinson, 2013 ; Krahwinkler et Rossmann, 2013 ; Lu et Weng, 2007). Chaque type d'image présente des qualités et des faiblesses. Ainsi, les images à haute et très haute résolution spatiale présentent généralement une faible répétitivité temporelle, qui est plutôt caractéristique des images à moyenne et faible résolution spatiale. Un compromis doit ainsi être trouvé entre la résolution spatiale et la résolution spectrale des images ainsi que l'étendue géographique du site d'étude, en cohérence avec les objectifs de recherche (Atkinson, 2013 ; Cihlar, 2000).

Si l'exploitation de séries temporelles est retenue, on privilégiera la haute répétitivité temporelle au détriment de la résolution spatiale. Dans le cas contraire, on privilégiera la résolution spatiale et l'étude pourra se baser sur l'exploitation d'images multispectrales sur une date ou multi-dates. On peut avoir recours à la fusion de données pour contourner ces compromis. La fusion de données consiste à combiner les informations fournies par des images de différentes résolutions spatiales, spectrales ou temporelles, pouvant provenir de capteurs différents, afin de tirer parti des avantages de chacune d'elle (Lu et Weng, 2007). L'application de cette méthode consiste à assembler les différentes données dans une même série, sous la forme d'un fichier unique, puis à combiner les différentes informations spectrales associées à un point du site d'étude (pixel ou autre unité spatiale) pour obtenir une signature améliorée (Amarsaikhan et Douglas, 2004 ; Zhang, 2004 ; Zhu et Tateishi, 2006). L'apport de cette méthode a été mis à profit pour améliorer de nombreux travaux de cartographie de la végétation (Xie et al., 2008). Les produits satellitaires tels que ceux de la mission Sentinel-2 permettent de constituer des séries temporelles combinant haute répétitivité temporelle et haute résolution spatiale (D'Odorico et al., 2013 ; Dotzler et al., 2015 ; Drusch et al., 2012 ; Hill, 2013).

Il est en effet également possible de tirer parti de la résolution spectrale des données. Il a été démontré que plus les bandes spectrales étaient nombreuses et fines, meilleure était la capacité de distinction des classes (Turner, 1990). Il a également été démontré que l'apport de la temporalité pour l'augmentation de la précision de la classification pouvait être compensé par l'augmentation de la résolution spectrale (Krahwinkler et Rossmann, 2013).

Le choix porte également sur la nature des images de télédétection. Pour cartographier la végétation, il est possible de se baser uniquement sur des réflectances, mais aussi de recourir à des indices de végétation, des « métriques phénologiques » (Pettorelli et al., 2005). Les informations relatives à la texture de la végétation peuvent également être exploitées pour distinguer différents types d'occupation des sols, ou différents types forestiers (Dengsheng et al., 2011 ; Lu et al., 2008 ; Lu et Weng, 2007 ; Rodriguez-Galiano et Chica-Olmo, 2012 ; Rodriguez-Galiano et al., 2012a).

Les images de télédétection en entrée de classification peuvent être complétées de données ancillaires, fournissant une information différente, destinées à améliorer encore la distinction des classes. Dans le cas de la cartographie de la végétation, on pourra avoir recours, en complément des réflectances spectrales, à des informations relatives à la texture (Lu et al., 2008 ; Zhu et Liu, 2014). Dans le cas d'un territoire au relief accidenté tel qu'un massif montagneux, on aura fréquemment recours à des

données topographiques, sous la forme d'un modèle numérique de terrain et de ses plans dérivés (Dorren et al., 2003 ; Kuemmerle et al., 2006 ; Ren et al., 2009 ; Zhu et Liu, 2014).

La grande variété des données de télédétection aujourd'hui disponibles peut conduire à penser que, plus on accumulera d'informations différentes, meilleurs seront les résultats de classification. Toutefois, la combinaison d'un trop grand nombre de variables en entrée de classification n'équivaut pas à la somme de leurs apports individuels. Le traitement d'un nombre croissant de variables n'améliore la performance de la classification que jusqu'à un certain point. Au-delà, la précision des résultats peut s'en trouver dégradée (Dengsheng et al., 2011 ; Price et al., 2002).

2.2.4 Choix d'un algorithme de classification adapté

Le choix de l'algorithme de classification a une influence sur la précision des résultats obtenus (Hubert-Moy et al., 2001). Il en existe actuellement un très grand nombre, dont les règles de décision sont très variées. Il est possible d'établir une typologie des algorithmes de classification selon les caractéristiques de ces règles de décision. On distingue ainsi communément deux grands groupes, opposant les algorithmes de classification dits paramétriques et les algorithmes non paramétriques (Lu et Weng, 2007).

Les algorithmes paramétriques reposent sur l'hypothèse d'une distribution gaussienne des données d'entrée (Hubert-Moy et al., 2001 ; Lu et Weng, 2007). La distribution gaussienne correspondant à chaque classe est décrite à partir du jeu d'entraînement par le calcul d'un vecteur moyen et d'une matrice de covariance, qui serviront ensuite de référence pour distinguer les classes en affectant les pixels à ces dernières de façon supervisée. Historiquement, les algorithmes paramétriques sont les plus anciennement utilisés. Parmi de nombreux exemples, un grand nombre de travaux se sont basés sur le maximum de vraisemblance. Il s'agit d'une approche probabiliste qui utilise le comportement spectral d'une classe sous la forme d'une distribution de probabilités centrées autour d'un comportement spectral moyen (figure 4). Cet algorithme attribue une classe à un pixel donné selon une valeur de probabilité d'appartenance à cette classe, calculée par une fonction discriminante gaussienne. Le maximum de vraisemblance est connu pour sa grande robustesse, expliquant son usage fréquent pour de nombreux travaux de classification depuis l'émergence des données de télédétection (Carvalho et al., 2004 ; Huang et al., 2002 ; Kuemmerle et al., 2006 ; Lu et Weng, 2007 ; Nangendo et al., 2007 ; Ren et al., 2009 ; Srivastava et al., 2012 ; Xie et al., 2008 ; Zhang et al., 2007). A ce titre, il constitue une référence historique de la classification de l'occupation des sols par télédétection.

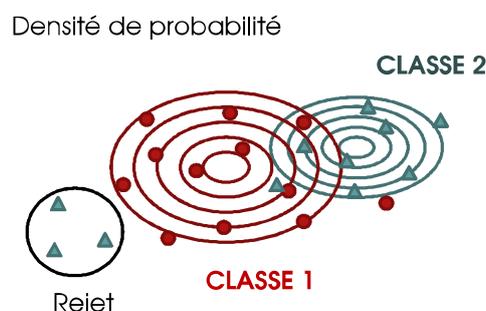


Figure 4 : Attribution d'une classe à différents pixels selon l'approche probabiliste du maximum de vraisemblance.

La classification par maximum de vraisemblance peut être basée sur un principe d'équiprobabilité des classes ou sur une connaissance *a priori* de ces probabilités. Cette deuxième approche met en exergue certaines classes par rapport à d'autres (Strahler, 1980). La fonction discriminante du maximum de vraisemblance attribue les classes à l'ensemble des pixels à classer, même si leur probabilité d'appartenance est très faible quelle que soit la classe. Ces pixels peuvent être considérés comme mal classés. Le maximum de vraisemblance permet de créer une classe de rejet à attribuer à ces pixels mal classés du fait d'une probabilité trop faible (figure 4). On définit pour cela un seuil de rejet correspondant à la valeur minimale admissible de cette probabilité.

Les algorithmes non paramétriques ne reposent sur aucun prérequis quant aux caractéristiques statistiques de la distribution des données. Ces algorithmes sont très nombreux et se basent sur des règles de décision différentes. Les méthodes Support Vector Machine (SVM), Random Forest (RF) et les réseaux de neurones font partie des algorithmes non paramétriques les plus employés pour des travaux de classification (Huang et al., 2002).

L'algorithme SVM (Cortes et Vapnik, 1995) repose sur le principe d'apprentissage automatique. Il comporte deux phases. La première phase, dite d'apprentissage, consiste à déterminer un modèle de classification à partir des échantillons du jeu d'entraînement. La deuxième phase, dite de test, consiste à appliquer le modèle à la totalité de la population à classer. SVM est une approche de classification linéaire consistant à définir et à optimiser en phase d'apprentissage un hyperplan de séparation entre chaque classe, calculé par une fonction. L'hyperplan présentant la marge la plus importante (marge maximale) entre les signatures du jeu d'entraînement est systématiquement retenu en fin de phase d'apprentissage, aboutissant à la construction du modèle de classification (figure 5).

L'algorithme SVM, très largement étudié, est devenu un outil incontournable dans le domaine de la classification d'images (Alcantara et al., 2013 ; Alcantara et al., 2012 ; Brown et al., 1999 ; Carrão et al., 2007 ; Carrão et al., 2008 ; Foody et Ajay, 2004 ; Foody et Mathur, 2006 ; Hsu et al., 2010 ; Huang et al., 2002). Il est particulièrement connu pour son absence de sensibilité à un grand nombre de variables en tant que données d'entrée (Carrão et al., 2007 ; Huang et al., 2002).

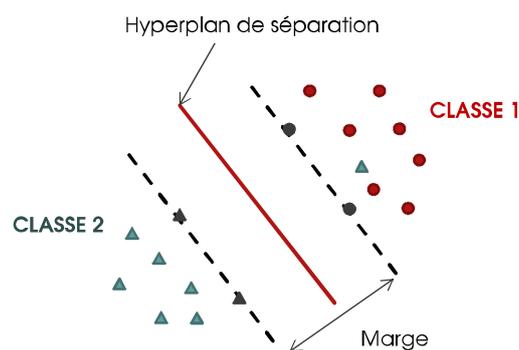


Figure 5 : Séparation des classes selon l'algorithme SVM : définition de l'hyperplan de séparation à marge maximale.

L'algorithme Random Forest (Breiman, 2001) repose aussi sur le principe d'apprentissage automatique. Avec cet algorithme, la séparation des classes est assurée par un ensemble d'arbres de décision générés aléatoirement, désigné sous l'appellation de « forêts aléatoires » (figure 6). Ces arbres de décision sont appliqués à des sous-ensembles du jeu d'entraînement en phase

d'apprentissage. Le modèle final de partition, qui est celui qui donne les classes les plus homogènes, est appliqué à l'ensemble des pixels de l'image pour la classification.

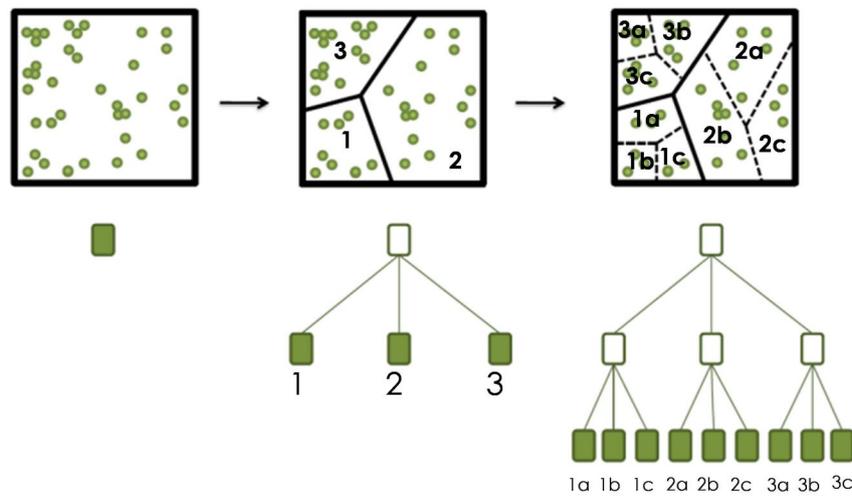


Figure 6 : Séparation des classes selon l'algorithme random forest : séparations successives par une suite d'arbres de décision générés aléatoirement.

L'algorithme Random Forest est relativement récent d'un point de vue historique. Il est toutefois actuellement autant employé que la méthode SVM pour des travaux de classification, du fait de sa performance en termes de précision des résultats et de sa capacité à traiter des données d'entrée complexes sur le plan spatial ou spectral (Abdel-Rahman et al., 2014 ; Gislason et al., 2006 ; Grinand et al., 2013 ; Immitzer et al., 2012 ; Li et al., 2014 ; Puissant et al., 2014 ; Rodriguez-Galiano et al., 2012b).

D'une façon générale, il reste difficile d'identifier l'algorithme de classification le plus approprié pour atteindre les objectifs souhaités. Ce choix est actuellement rendu malaisé par la grande variété d'algorithmes existants et dont l'efficacité est mise en avant par de nombreux travaux. Tous présentent des avantages et des inconvénients et l'algorithme optimal sera différent selon les données à traiter, les objectifs de recherche et les caractéristiques du site d'étude (Dengsheng et al., 2011). Dans ce contexte, de nombreux travaux ont été menés dans l'objectif de comparer les principaux algorithmes de classification, d'en évaluer les performances respectives ou d'identifier d'éventuelles limites (Abdel-Rahman et al., 2014 ; Li et al., 2014 ; Pal, 2005 ; Pal et Mather, 2005 ; Puissant et al., 2014 ; Rodriguez-Galiano et Chica-Olmo, 2012 ; Schneider, 2012 ; Xie et al., 2008).

Les réseaux de neurones font partie des algorithmes « améliorés » de classification, développés pour obtenir de meilleurs résultats que les algorithmes traditionnels. Ils sont particulièrement adaptés pour des travaux de cartographie d'une végétation d'organisation spatiale complexe (Xie et al., 2008). Des études ont prouvé que les résultats obtenus avec cet algorithme présentaient une précision nettement meilleure qu'avec le maximum de vraisemblance (Xie et al., 2008). Il présente toutefois deux limites notables. La première est liée à son effet « boîte noire » qui contraint l'interprétation des résultats obtenus. La deuxième limite est liée à la capacité de traitement que requiert cette méthode, qui est susceptible de n'aboutir à aucun résultat, même après de longs temps de calcul (Xie et al., 2008).

Les principales conclusions découlant de ces travaux ne mettent pas en avant un algorithme qui serait fondamentalement meilleur que les autres. La principale limite du maximum de vraisemblance est atteinte si les données d'entrée ne respectent pas ses prérequis en termes de distribution statistique. Ainsi, si pour une classe donnée les échantillons d'entraînement présentent une grande variabilité spectrale, incompatible avec une distribution gaussienne, les résultats obtenus s'en trouveront dégradés (Hubert-Moy et al., 2001 ; Xie et al., 2008). Il est établi que la complexité spatiale (structure paysagère) et spectrale de la végétation joue un rôle dans le choix de l'algorithme. Dans le cas d'un paysage complexe, il a ainsi été prouvé que les algorithmes non paramétriques donnaient de meilleurs résultats (Foody, 2002 ; Lu et Weng, 2007 ; Paola et Schowengerdt, 1995). Ils se distinguent également par une meilleure capacité à traiter des données d'entrée bruitées ou un grand nombre de dimensions (Abdel-Rahman et al., 2014 ; Rodriguez-Galiano et al., 2012b).

Les algorithmes non paramétriques ne sont toutefois pas dépourvus d'inconvénients. Ainsi, ils sont sensibles à l'équilibre des effectifs d'échantillons par classe dans le jeu d'entraînement. Il a ainsi été établi que RF avait tendance à sous-estimer dans ses résultats les classes les moins représentées dans le site d'étude (Colditz et al., 2011 ; Puissant et al., 2014). Il en est de même pour SVM. Le maximum de vraisemblance ne présente pas ce désavantage. Par ailleurs, les algorithmes non paramétriques présentent un effet « boîte noire » qui ne permet pas de retrouver les règles à l'origine de l'attribution des classes. De même, la notion de rejet n'existe pas avec ces approches, ce qui ne permet pas d'identifier des pixels bien ou mal classés. Avec le maximum de vraisemblance et sa classe de rejet, il est possible d'identifier les pixels les moins bien classés et de traiter, par une modification du jeu d'entraînement, les erreurs de classification.

Les algorithmes SVM et RF présentent des paramètres qu'il convient d'ajuster avant de mettre en œuvre la classification. Une valeur par défaut est proposée par les algorithmes pour certains de ces paramètres et une majorité de travaux reposent sur ces valeurs (Pal, 2005 ; Pal et Mather, 2005 ; Puissant et al., 2014 ; Schneider, 2012). Il y a donc peu de recul actuellement sur l'influence de la valeur de ces paramètres sur la précision des résultats et sur les méthodes d'ajustement optimal de cette valeur. Dans ce contexte, la mise en œuvre de ces algorithmes peut s'avérer délicate ou mal maîtrisée (Foody, 2004 ; Rodriguez-Galiano et al., 2012b).

Enfin, certains algorithmes sont connus pour mobiliser beaucoup de capacités informatiques et présenter des temps de calcul importants, voire, dans le cas des réseaux de neurones, des blocages n'aboutissant à aucun résultat pertinent lorsque la quantité de données d'entrée est trop importante (Xie et al., 2008).

2.2.5 *Traitement post-classification*

Les traitements post-classification visent à rectifier d'éventuelles anomalies ou erreurs de la cartographie une fois produite et ainsi à augmenter la précision des résultats (Dengsheng et al., 2011). Il a été établi que ces méthodes, utilisées à bon escient, peuvent contribuer à améliorer de façon notable la qualité des classifications (Lu et Weng, 2004). Parmi les traitements usuels, on a fréquemment recours à la rectification de l'effet « poivre et sel », ou « speckle », généré par les méthodes paramétriques traditionnelles. Il est également possible de regrouper *a posteriori* certaines classes, par exemple en procédant à des fusions de plusieurs classes en une seule. Enfin, des données ancillaires telles que celles qui ont été décrites précédemment peuvent aussi être utilisées en aval et non en entrée de la classification pour en améliorer les résultats. Pour la végétation forestière de montagne, il est ainsi possible d'améliorer les résultats de classification en utilisant des informations relatives à l'altitude, la pente ou l'exposition. En milieu urbain, il est possible de corriger de

mauvaises affectations d'occupation des sols en utilisant des données de densité de population (Lu et Weng, 2007).

2.2.6 Evaluation de la qualité des résultats

L'évaluation de la qualité des résultats est une étape indispensable de la démarche de classification (Cihlar, 2000 ; Foody, 2002 ; García-Mora et al., 2011 ; Lu et Weng, 2004 ; Stehman, 2009). Elle est très couramment basée sur l'évaluation de la précision de classification (Dengsheng et al., 2011). La précision d'une classification d'occupation des sols caractérise le degré de cohérence de la cartographie produite avec la « vérité terrain » (Foody, 2002 ; Stehman, 2009). Cette dernière, contenue dans le jeu de validation, peut correspondre aux données de référence ayant servi de base à la classification (Friedl et al., 2010), à d'autres cartes d'occupation des sols (Boles et al., 2004) ou de données issues d'une plus forte résolution spectrale (Friedl et al., 2002 ; García-Mora et al., 2011). La grande majorité des travaux ont recours à la matrice de confusion (Congalton, 1991), devenue un outil de référence pour l'évaluation de la précision de classification (Foody, 2002 ; Lu et Weng, 2004).

La matrice se compose de lignes et de colonnes confrontant les résultats de classification et les données de validation. L'exemple du tableau 2 présente le cas d'une validation croisée avec en ligne les données de référence et en colonne les résultats de classification. Chaque cellule de la matrice représente la proportion surfacique d'aire d'étude correspondant à la classe de référence indiquée par la ligne et classée par la carte tel qu'indiqué par la colonne. Les valeurs de cellules dans la diagonale (en gras et en bleu) correspondent donc aux pixels correctement classés (même classe que la référence) et les autres aux pixels mal classés.

Tableau 2 : Exemple de matrice de confusion, d'après (Stehman, 2009).

Classification						
Données de référence	Classification				Total ligne	Précision producteur (PA) (1-erreur de commission)
	1	2	...	k		
1	P₁₁	P ₁₂	...	P _{1k}	P _{1.}	P₁₁/P_{1.}
2	P ₂₁	P₂₂	...	P _{2k}	P _{2.}	P₂₂/P_{2.}
...
k	P _{k1}	P _{k2}	...	P_{kk}	P _{k.}	P_{kk}/P_{k.}
Total colonne	P _{.1}	P _{.2}	...	P _{.k}		
Précision utilisateur (UA) (1-erreur de commission)	P₁₁/P_{.1}	P₂₂/P_{.2}		P_{kk}/P_{.k}		

Des indicateurs de précision peuvent être calculés à partir de la matrice de confusion, permettant ainsi d'estimer la précision globale ou par classe d'une classification. Les principaux indicateurs couramment utilisés sont l'indice de Kappa, la précision globale, la précision producteur, la précision utilisateur, le F-Score, l'erreur de commission et l'erreur d'omission.

Fréquemment employé pour l'évaluation de la précision de résultats de classification, l'indice de Kappa (Congalton, 1991 ; Foody, 2002 ; Stehman et Czaplewski, 1998), qu'on notera K, est calculé à partir de la formule suivante :

$$K = \frac{N \sum_{i=1}^r x_{ii} - \sum_{i=1}^r (x_{i+} * x_{+i})}{N^2 - \sum_{i=1}^r (x_{i+} * x_{+i})}$$

Équation 1: Indice de Kappa, où N est le nombre total d'observations, r est le nombre de lignes de la matrice de confusion, x_{ii} est le nombre d'observations correspondant à la ligne i et à la colonne i, x_{i+} et x_{+i} sont les totaux respectifs de la ligne i et de la colonne i.

La valeur de K est comprise entre 0 et 1. La précision globale (Overall Accuracy ou OA) est un autre indicateur de précision permettant d'évaluer la précision d'une classification entière et correspond au rapport entre la surface totale bien classée et la surface totale traitée par la classification (Congalton, 1991):

$$OA = \frac{n}{N}$$

Équation 2: Précision globale, où N est le nombre total d'observations et n le nombre d'observations correspondant à un bon classement.

La précision producteur de chaque classe indique la proportion de pixels correctement classés pour cette classe par rapport à la totalité des pixels de cette classe dans les données de référence (Congalton, 1991).

Elle indique la probabilité qu'un pixel de la carte de référence soit correctement classé, en lien avec la notion d'erreur d'omission. Elle sera notée PP :

$$PP = \frac{x_{ii}}{x_{+i}}$$

Équation 3: précision producteur, où x_{ii} est le nombre de pixels correctement classés pour une catégorie (correspondant à la ligne i et à la colonne i) et x_{+i} est le total de pixels de cette catégorie dans la référence (total de la colonne i).

La précision utilisateur de chaque classe indique la proportion de pixels correctement classés pour cette classe par rapport à la totalité des pixels de cette classe dans la classification (Congalton, 1991). Elle indique la probabilité qu'un pixel de la classification soit correctement classé, en lien avec la notion d'erreur de commission. La précision utilisateur permet ainsi d'évaluer dans quelle proportion chacune des formations cartographiées est correctement classée. Elle sera nommée PU :

$$PU = \frac{x_{ii}}{x_{i+}}$$

Équation 4: précision utilisateur, où x_{ii} est le nombre de pixels correctement classés pour une catégorie (correspondant à la ligne i et à la colonne i) et x_{i+} est le total de pixels affectés à cette catégorie (total de la ligne i).

Le F-Score intègre dans son calcul les valeurs de PP et de PU (Powell, 2011):

$$F - Score = \frac{2 \cdot PU \cdot PP}{PP + PU}$$

Équation 5: F-Score, où PU est la précision utilisateur et PP la précision producteur.

L'erreur d'omission (EO) correspond à la probabilité conditionnelle pour qu'un point choisi au hasard classé j par les données de référence soit classé k par la carte (Congalton, 1991 ; Stehman et Czaplewski, 1998). On peut également définir l'erreur d'omission par rapport à la précision producteur :

$$EO = 1 - PP$$

Équation 6: Erreur d'omission, où PP est la précision producteur.

L'erreur de commission (EC) correspond à la probabilité conditionnelle pour qu'un point choisi au hasard classé j par la carte soit classé k par les données de référence (Congalton, 1991 ; Stehman et Czaplewski, 1998). On peut également définir l'erreur de commission par rapport à la précision utilisateur :

$$EC = 1 - PU$$

Équation 7: Erreur de commission, où PU est la précision utilisateur.

L'indice de Kappa est reconnu comme un outil très efficace pour analyser une matrice de confusion ou en comparer plusieurs (Congalton, 1991 ; Foody, 2004). Certains travaux ont toutefois établi qu'une évaluation de la précision basée sur le seul indice de Kappa restait limitée et ont préconisé l'utilisation, en complément de cet indice, de plusieurs des indicateurs présentés ci-dessus (Foody, 2002) ou d'autres indices prenant en compte explicitement la localisation des pixels (Pontius, 2000).

Certains facteurs ont une influence sur l'évaluation de la précision de classification. C'est le cas de la méthode de sélection des échantillons pour construire le jeu de validation (Scott Overton et Stehman, 1993). Cette influence est d'autant plus marquée dans le cas d'une validation croisée, utilisant les données de référence ayant servi de base à la classification. Il est alors nécessaire d'utiliser un jeu de validation indépendant du jeu d'entraînement (Congalton, 1991 ; García-Mora et al., 2011 ; Stehman et Czaplewski, 1998).

2.3 Les limites de la classification supervisée

La classification supervisée présente des limites qui contraignent le niveau de précision thématique des cartographies obtenues. Ainsi, les cartes de la végétation forestière actuellement obtenues se limitent souvent à la distinction de grands types tels que les essences décidues, les résineux et les boisements mixtes (Xie et al., 2008).

Les travaux actuels font particulièrement état de l'effet de la résolution spatiale et de la résolution spectrale des données d'entrée (similarité interclasse et variabilité spatiale intra-classe des signatures) sur les résultats des classifications. L'effet des erreurs dans les données de référence déjà bien identifiées dans la littérature, explique aussi le manque de précision des classifications.

La résolution spatiale des données de télédétection est à l'origine des plus importantes erreurs et imprécisions dans les résultats de classification d'occupation des sols (Boyd et Foody, 2011 ; Lu et Weng, 2007 ; Nagendra, 2001). Dans le cas d'une résolution spatiale trop faible, il est difficile de distinguer certaines classes. Cette difficulté est principalement due à la présence de pixels mixtes, dont la proportion est d'autant plus importante que la résolution spatiale est faible (Boyd et Foody, 2011).

La surface d'un pixel mixte, tel que ce dernier est défini par la bibliographie, couvre plusieurs classes et non une classe unique. En ce sens, le pixel mixte déroge à l'une des règles de base de toute classification « directe », qui suppose qu'une seule classe doit être attribuée à chaque pixel à classer (Boyd et Foody, 2011 ; Nagendra, 2001). Les pixels mixtes sont particulièrement concentrés à la frontière délimitant deux ou plusieurs classes. La signature résultante d'un pixel mixte est « composite », correspondant à une moyenne pondérée des signatures représentatives de chaque classe concernée (Lu et Weng, 2004 ; Lu et Weng, 2007 ; Nagendra, 2001). Plus la résolution spatiale est basse, plus la taille du pixel est importante et plus le nombre de classes intersectées peut être grand. Il sera alors d'autant plus difficile, dans le cadre d'une classification « directe », d'attribuer une unique classe au pixel. Dans ce contexte, plus le site d'étude à traiter est étendu, ou plus la structure paysagère de la végétation est fragmentée, plus la proportion de pixels mixtes et le manque de précision de classification seront importants (Broich et al., 2009 ; Foody et al., 1997 ; Giri et al., 2013 ; Sulla-Menashe et al., 2011). Cette précision insuffisante est d'autant plus marquée dans le cas de l'utilisation d'un algorithme paramétrique traditionnel tel que le maximum de vraisemblance, du fait des règles de décision régissant son fonctionnement. Il serait logique de penser que l'usage de données à haute résolution spatiale permet de s'affranchir de cette problématique. Ce n'est toutefois pas le cas, car la problématique des pixels mixtes peut alors être liée à la présence d'hétérogénéités « intra-classe » (Lu et Weng, 2007 ; Nagendra, 2001).

La résolution spectrale des données d'entrée, est aussi une cause importante des erreurs et imprécisions dans les résultats de classification d'occupation des sols. Elle intervient au niveau de la capacité à distinguer des essences dont la signature spectrale et le profil phénologique sont similaires (Xie et al., 2008). En pratique, il est difficile de distinguer des espèces appartenant à un groupe d'essences proches, par exemple différents pins, chênes sempervirents ou chênes caducs. Nous nommerons ce phénomène la similarité inter-classe. Cette difficulté est renforcée dans le cas d'une végétation de composition hétérogène ou d'une structure paysagère complexe. C'est le cas, par exemple, des massifs de montagne (Kuemmerle et al., 2006). Elle peut également induire une variabilité spectrale de la signature représentative d'une même essence entre deux points du territoire (Nagendra, 2001 ; Ren et al., 2009 ; Sha et al., 2008). En effet, si l'on travaille sur de grandes étendues, la variabilité spatiale des conditions d'environnement peut entraîner une modification locale

du comportement phénologique d'une formation végétale. Nous nommerons ce phénomène la variabilité intra-classe. Ce facteur réduit le caractère représentatif de la signature d'une formation, ce qui entraîne des erreurs de classification (Cihlar, 2000 ; Colditz et al., 2011 ; Justice et al., 1986 ; Krishna Prasad et al., 2007 ; Nagendra, 2001 ; Zhou et al., 2003). Ces difficultés sont accentuées dans les zones montagneuses où les variations d'altitude et d'exposition créent des conditions bioclimatiques diverses, ce qui augmente la complexité et la variabilité de la distribution spatiale de la végétation et de son fonctionnement phénologique (Balthazar et al., 2012 ; Blesius et Weirich, 2005 ; Cihlar, 2000 ; Colditz et al., 2011 ; Dorren et al., 2003 ; Kuemmerle et al., 2006 ; Ren et al., 2009).

La qualité des données de référence influe aussi sur les résultats de classification d'occupation des sols. Toute procédure de classification supervisée se base sur des références qu'elle assimile à une « vérité » terrain. Dans ce contexte, l'information fournie par ces données est souvent intégrée dans la procédure sans être remise en question. Il est pourtant erroné de partir de l'hypothèse que les données de référence ont une précision proche de 100%, surtout si ces données sont issues de la photo-interprétation de photographies aériennes. En effet, la délimitation et la caractérisation de peuplements forestiers par cette méthode repose en partie sur un jugement subjectif, dépendant du photo-interprète (Franklin, 2001). Il a été démontré que les erreurs qu'elles contiennent ont une très forte répercussion sur la précision des résultats de classification (Foody, 2010). Cette dernière se trouve ainsi limitée dès le départ, même dans le cas d'une procédure de classification optimale. Il est ainsi nécessaire d'évaluer la qualité des données de référence servant de base à la classification, afin de pouvoir en tenir compte pour évaluer la qualité des résultats obtenus. La méthode la plus couramment employée consiste à comparer ces données avec des relevés de terrain provenant d'une autre source.

3 Démarche et objectifs

3.1 Définition d'une procédure de classification supervisée adaptée à la cartographie des essences forestières à une échelle régionale

Ce travail de thèse porte sur l'étude de la procédure de classification supervisée d'une série temporelle d'images de télédétection appliquée à la cartographie des peuplements forestiers à l'échelle régionale. Il répond au besoin cartographique de combiner, dans un même document, la vision synoptique de la végétation forestière et la composition végétale détaillée sur un territoire étendu.

Ce contexte implique de se confronter aux limites méthodologiques actuelles évoquées plus tôt, sources d'erreurs et imprécisions. **L'objectif général des travaux présentés est d'améliorer la procédure de classification supervisée afin de cartographier plus précisément la végétation forestière, tant au niveau quantitatif (taux d'erreur) que thématique (nombre de classes identifiées).**

Préalablement à l'application de la procédure de classification supervisée, une réflexion a été menée afin de procéder au choix du site d'étude, des données image en entrée de classification et des données de référence servant de base à l'élaboration de la nomenclature.

Pour répondre au besoin cartographique, le site d'étude doit à la fois présenter une surface importante, correspondant à une échelle régionale, mais aussi une étendue de végétation suffisamment grande pour garantir la diversité de ses essences. Le choix s'est porté sur le massif des Pyrénées. Cette zone de montagne, à cheval sur trois pays et deux régions sur le territoire français, présente une surface forestière très importante. Elle est notamment soumise à des conditions climatiques et topographiques très contrastées sur l'ensemble de sa superficie. Sa végétation, influencée par ces conditions, présente une grande variabilité de composition ainsi qu'une organisation spatiale complexe. Du fait de son caractère montagneux, certaines essences forestières sont emblématiques d'un ensemble de conditions climatiques et topographiques locales au sein du massif. Cela influence également le niveau de mélange et de fragmentation des peuplements, qui peuvent suivre une organisation étagée selon l'altitude, présenter des zones de gradient ou encore des structures mosaïquées bien plus complexes. Ce site d'étude est présenté dans le chapitre II, ses caractéristiques géographiques, topographiques, climatiques ainsi que celles de sa végétation y sont détaillées.

Le site d'étude choisi présente l'avantage d'être intégralement couvert par des inventaires forestiers nationaux français, espagnols et andorrans. Ces inventaires caractérisent les essences composant le couvert forestier et peuvent servir de base à l'élaboration des données de référence nécessaires à la classification. Ces informations ont non seulement permis de disposer de données de référence quasi-exhaustives pour la totalité du massif, mais également d'une caractérisation suffisamment complète des essences forestières pour construire une nomenclature adaptée à une précision thématique élevée. Dans cette optique, une base de données a été constituée avec l'ensemble des inventaires disponibles. Les méthodes de caractérisation des formations forestières varient d'un pays à l'autre, cette base de données cartographiques a fait l'objet d'un travail d'harmonisation, présenté en chapitre II. La cartographie forestière obtenue, homogène pour l'ensemble du massif pyrénéen, a servi de base à l'élaboration d'une nomenclature forestière détaillée et a également fourni les données de référence pour la construction des jeux d'entraînement et de validation. Ces éléments sont présentés et décrits dans le chapitre II.

Nous avons choisi d'utiliser des séries temporelles d'images pour effectuer la classification du couvert forestier. Les signatures utilisées pour la distinction des classes sont donc temporelles et non purement spectrales. Dans ce contexte, les essences sont distinguées selon la variabilité de leur réponse spectrale au cours du temps, cette réponse étant conditionnée par leur fonctionnement phénologique, ce qui permet de mieux les caractériser.

La dimension temporelle constitue donc un critère primordial auquel les données satellitaires choisies doivent répondre. Le comportement phénologique de la végétation forestière suivant un cycle annuel, il est nécessaire de pouvoir obtenir un nombre important de dates sur une année pour constituer une signature précise et représentative de la classe concernée. Il est par ailleurs nécessaire de disposer de données pluri-annuelles, idéalement à des dates identiques d'une année sur l'autre. L'ensemble de ces prérequis caractérise la haute répétitivité temporelle.

La dimension spectrale conditionne également directement le choix des données satellitaires. La part de la réponse spectrale de la végétation directement corrélée à son comportement phénologique est particulièrement décelable en analysant les réflectances du couvert dans les domaines du rouge et du proche infrarouge. Nous avons choisi d'utiliser ces bandes spectrales optiques, qui servent au calcul des indices EVI et du NDVI.

Du fait de l'étendue du territoire à cartographier, la dimension spatiale constitue un critère moins indispensable à la constitution des séries temporelles. Néanmoins, la résolution spatiale doit être suffisante pour caractériser la complexité spatiale de la végétation en réduisant la perte de précision liée aux pixels « mixtes ».

Les données satellitaires répondant le mieux à ces prérequis sont les données issues du capteur MODIS Terra. Elles présentent en effet une haute répétitivité temporelle, avec des données journalières à partir desquelles sont produites des synthèses tous les 8 jours ou tous les 16 jours selon les produits, ce qui permet de constituer des séries temporelles d'au moins 23 dates par an. Le pas de temps des acquisitions est régulier d'une année sur l'autre et les dates sont identiques, ce qui permet, le cas échéant, de calculer des moyennes mensuelles ou à la date pour une période de plusieurs années. Les données sont disponibles à partir de l'année 2000 et les acquisitions de ce capteur sont toujours en cours. Sur le plan spectral, le capteur MODIS Terra propose des données de réflectance dans le rouge et le proche infrarouge, mais aussi d'indices de végétation tels que le NDVI et l'EVI. Les données issues du capteur MODIS Terra présentent une résolution spatiale plus précise que la plupart des autres capteurs à haute répétitivité temporelle, c'est-à-dire 250 m. Cette résolution est faible mais reste adaptée à une analyse d'échelle régionale et à l'échelle de délimitation des formations forestières présentée par les données de référence. Une base de données images, décrite dans le chapitre II, a été constituée à partir de ces données et a servi de base à la construction des séries temporelles étudiées pour les travaux de thèse.

3.2 Objectifs de thèse et organisation du mémoire

L'objectif général de la thèse peut être décliné en un objectif thématique et un objectif méthodologique. L'objectif thématique consiste à identifier par télédétection les peuplements purs ou en mélange d'essences forestières sur un territoire de vaste étendue. L'objectif méthodologique consiste à définir la configuration optimale de la procédure de classification supervisée permettant d'obtenir les meilleurs résultats.

Afin d'atteindre ces objectifs, les travaux menés dans cette thèse sont articulés selon trois volets successifs:

Le premier volet consiste à évaluer l'apport d'une méthode de stratification pour améliorer la qualité de la classification de séries temporelles d'images. Pour cela, nous avons choisi d'appliquer cette méthode en classant de façon supervisée une série temporelle de NDVI dérivée d'images MODIS avec l'algorithme du maximum de vraisemblance. Dans le contexte du site d'étude MRS (MRS pour Moyenne Résolution Spatiale), dont la végétation est complexe et la surface importante, nous avons émis l'hypothèse que l'application d'une méthode de stratification contribuerait à augmenter la précision des résultats en réduisant la variabilité spatiale intra-classe et la similarité inter-classe des signatures temporelles des espèces forestières. La méthodologie appliquée et les résultats obtenus sont décrits et interprétés dans le chapitre III.

Le deuxième volet porte sur l'évaluation de l'apport du choix de l'algorithme et de l'organisation et de la durée de la série temporelle sur les résultats de la classification. A cette fin, trois procédures distinctes ont été comparées, chacune basée sur un algorithme de classification différent. Nous avons émis l'hypothèse que les données à traiter ne répondent pas aux prérequis statistiques nécessaires au bon fonctionnement de l'approche probabiliste du maximum de vraisemblance et que de meilleurs résultats seraient obtenus avec un algorithme s'affranchissant de ces contraintes. Nous avons alors choisi de comparer le maximum de vraisemblance avec deux algorithmes non paramétriques, SVM et Random Forest, qui sont mis en avant par la littérature pour leur efficacité dans le cadre de travaux de cartographie de la végétation. Nous avons aussi cherché à déterminer la configuration optimale de la procédure de classification permettant d'obtenir les meilleurs résultats de classification en focalisant notamment sur l'organisation et la durée de la série temporelle. A cette fin, différentes organisations de séries temporelles MODIS ont ainsi été traitées comparées. La méthodologie appliquée et les résultats obtenus sont décrits et interprétés dans le chapitre IV.

Le troisième volet est relatif à l'évaluation de l'effet du changement de résolution spatiale sur la qualité des résultats de la classification. Les travaux menés dans ce volet, qui constituent un approfondissement ceux qui ont été effectués dans le volet précédent, consistent à appliquer une démarche similaire à celle du deuxième volet à une série temporelle d'images à haute résolution spatiale (images DEIMOS). Les résultats sont produits en utilisant les meilleurs algorithmes identifiés dans le volet précédent à plusieurs configurations de séries temporelles. Nous avons émis l'hypothèse que le passage des données à moyenne résolution spatiale (séries MODIS) aux données à haute résolution spatiale (séries DEIMOS) permet d'améliorer la qualité de la classification obtenue, notamment la précision thématique des mélanges d'essences. La méthodologie appliquée et les résultats obtenus sont décrits, interprétés et analysés comparativement dans le chapitre V

Chapitre II : Site d'étude et données

1 Sites d'étude

Les travaux ont porté sur deux sites d'étude. Les études réalisées à l'échelle régionale, basées sur une série temporelle d'images à moyenne résolution spatiale MODIS, ont été effectuées sur le massif des Pyrénées dans sa totalité (ou site d'étude MRS). L'étude réalisée à l'échelle locale, basée sur une série d'images à haute résolution spatiale DEIMOS, concerne un secteur du versant nord de la haute chaîne pyrénéenne, situé dans le Haut Comminge et le Couserans (site d'étude HRS, pour Haute Résolution Spatiale).

1.1 Site d'étude MRS

Les Pyrénées s'étendent sur la France, l'Espagne et Andorre. La délimitation prise en compte dans l'étude correspond, côté français, à celle de l'entité administrative du massif des Pyrénées telle que définie par le décret ministériel du 9 janvier 1985. Plus précisément, le contour du site d'étude est défini par une zone tampon de 20 km à partir du périmètre du massif des Pyrénées (figure 7). Ce site s'étend sur le territoire pyrénéen des départements des Pyrénées-Atlantiques (région Aquitaine), des Hautes-Pyrénées, de la Haute-Garonne et de l'Ariège (région Midi-Pyrénées) et des Pyrénées-Orientales (région Languedoc-Roussillon). Côté espagnol, le périmètre inclut les zones de montagne et de piémont des communautés autonomes du Pays Basque, de la Navarre, de l'Aragon et de la Catalogne.

1.1.1 Caractéristiques géographiques

La chaîne montagneuse des Pyrénées s'étire d'Ouest en Est du Golfe de Gascogne à la Méditerranée sur environ 520 km et du Nord au Sud du piémont français au piémont espagnol sur environ 150 km. Sa superficie totale est d'environ 49 850 km². Le massif présente une grande variabilité au niveau de ses conditions topographiques et morphologiques, définissant plusieurs sous-ensembles. Le gradient altitudinal permet de découper le massif, côté français comme espagnol, en quatre zones d'élévation croissante (figure 7) : la plaine en dessous de 250 m, le piémont entre 250 m et 750 m d'altitude, la moyenne montagne entre 750 m et 2000 m et la haute montagne entre 2000 m et 3000 m. La principale ligne de crête, d'orientation Est-Ouest, correspond en grande partie à la frontière administrative franco-espagnole, qui le scinde en deux grands versants d'expositions Nord et Sud et définit l'orientation de la grande majorité des vallées pyrénéennes selon un axe Nord-Sud. Les deux versants possèdent des caractéristiques topographiques différentes, conférant au massif une dissymétrie de relief.

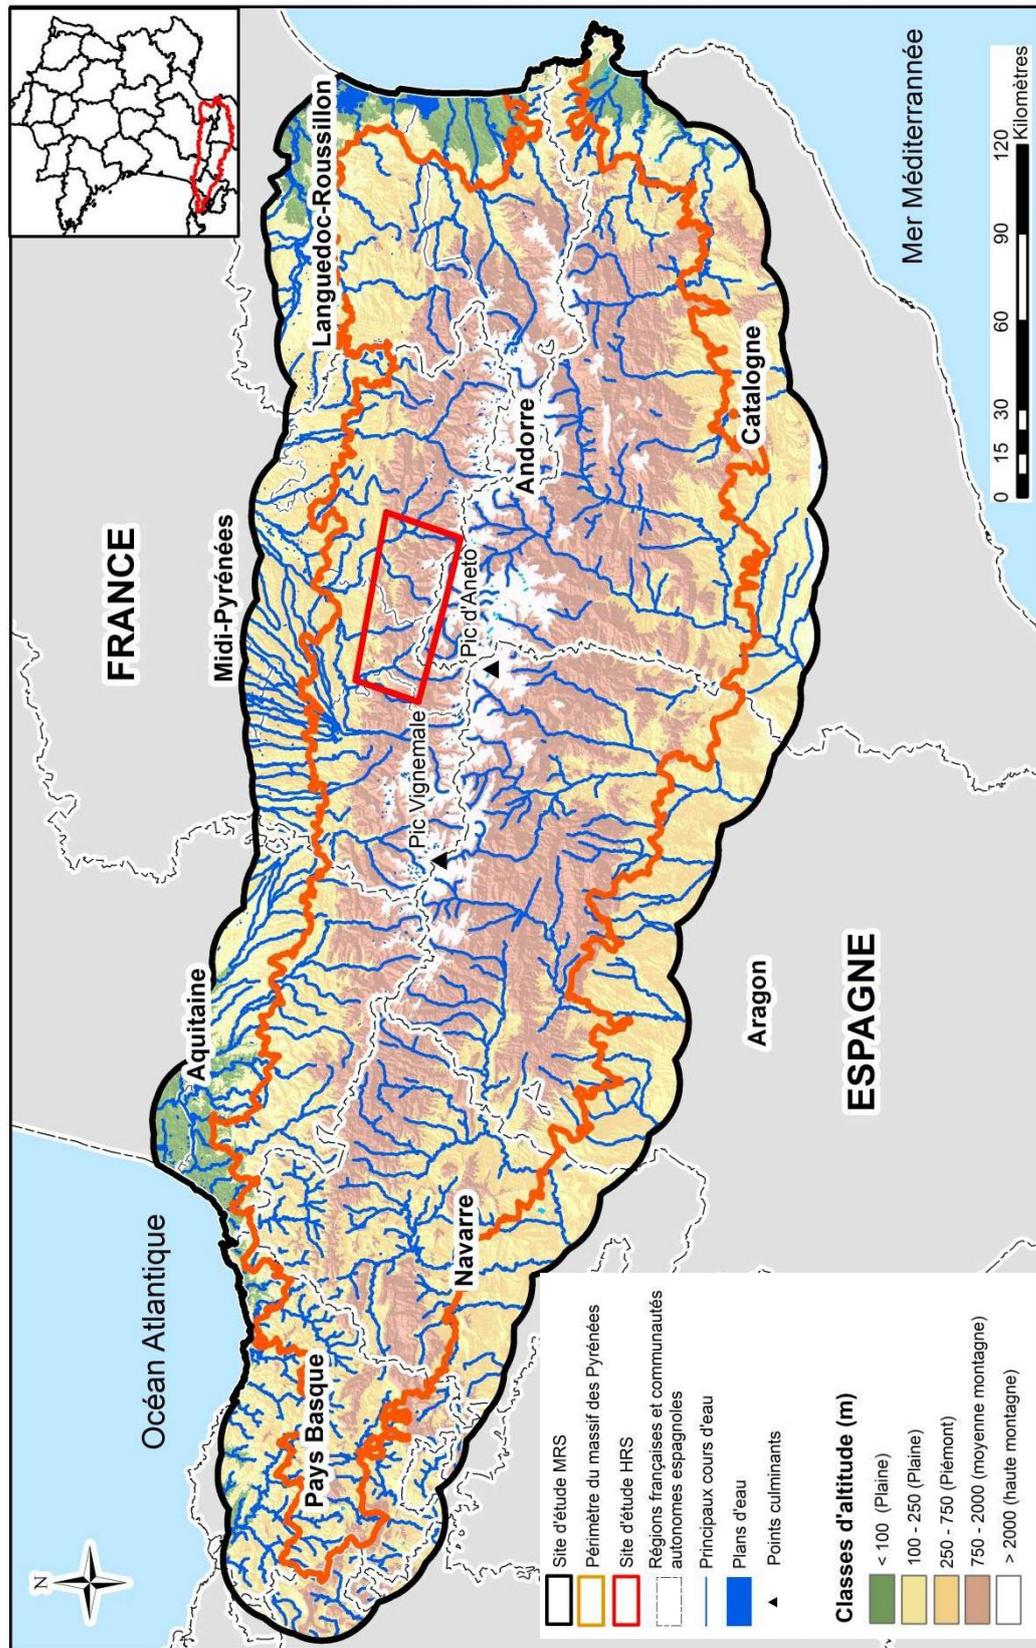


Figure 7 : Localisation des sites d'étude (sources : GEOFLA (IGN), BD CARTHAGE, SRTM)

Le versant Nord, situé en territoire français, représente environ 1/3 de la surface du massif. Ce versant se caractérise par un relief particulièrement abrupt et accentué, le sommet le plus élevé, le Pic de Vignemale, culminant à 3298 m. Le versant Sud, situé en territoire espagnol, correspond aux 2/3 de la surface du massif. Il présente un relief plus progressif mais aussi de nombreux accidents (sierras entrecoupées de canyons). On y observe des altitudes dépassant régulièrement 2000 m, le point culminant étant le Pic d'Aneto (3404 m).

Du fait de précipitations importantes sur son extrémité Ouest et dans sa partie centrale (climat océanique), de ses nombreux lacs et de ses altitudes élevées permettant la formation d'un manteau neigeux, le massif pyrénéen constitue une vaste zone de stockage de la ressource en eau. Il présente quatre grands bassins hydrographiques : le bassin de l'Elbe, d'une superficie d'environ 85 550 km², les bassins de la Garonne (55 000 km²) et de l'Adour (16 880 km²) et les bassins intérieurs de Catalogne (15 500 km²). Sur les façades Atlantique et Méditerranéenne, plusieurs petits bassins côtiers sont également présents. De part et d'autre de la ligne de crête, le système hydrologique s'organise, dans le versant Nord comme dans le versant Sud, en une série de vallées parallèles d'orientation Nord/Sud. A l'exception de l'Aragon, on observe une majorité de petites rivières de régime torrentiel. Le massif pyrénéen se particularise par un grand nombre de lacs d'altitude.

1.1.2 *Caractéristiques climatiques*

Du fait de son étendue, de ses caractéristiques topographiques et de sa position entre deux côtes, le massif des Pyrénées présente une importante variabilité climatique. Il est exposé à des vents d'orientations Ouest/Sud-Ouest et Nord/Nord-Ouest, amenant précipitations et influence océanique, ainsi qu'aux perturbations méditerranéennes ou méridionales dans son extrémité Est. Cette configuration de la chaîne entraîne un gradient climatique Est-Ouest. Le site d'étude se caractérise ainsi par un climat océanique sur la partie occidentale, marqué par des hivers doux et pluvieux et des étés frais et relativement humides, avec des cumuls de précipitations variant de 1000 à 2000 mm par an (figure 8). Sa partie Est et l'extrême Sud sont soumis à un régime de type méditerranéen, avec des hivers doux et humides, des étés chauds et secs et des précipitations moyennes annuelles inférieures à 800 mm. La partie centrale est, quant à elle, sous l'influence d'un climat sub-océanique froid avec des précipitations annuelles importantes, supérieures à 2000 mm, et des températures moyennes basses (OPCC et CTP, 2013 ; Soubeyroux et al., 2011). On peut noter également l'importance des précipitations en altitude, dépassant 1200 mm par an dès 2000 m.

La répartition des températures moyennes annuelles (figure 9) montre l'influence de l'altitude sur les caractéristiques thermiques du massif : la température moyenne annuelle varie entre 12,5 °C et 7,5 °C sur le piémont et jusqu'à environ 1000 m d'altitude et entre 7,5°C et 5 °C entre 1000 m et 2000 m. Au-delà, les valeurs moyennes ne dépassent pas 5 °C et sont négatives pour les plus hauts reliefs. On note également les moyennes de températures particulièrement élevées (supérieures à 12,5 °C et pouvant excéder 23°C) aux extrémités Est et Ouest du massif, correspondant respectivement aux zones d'influence méditerranéenne et océanique.

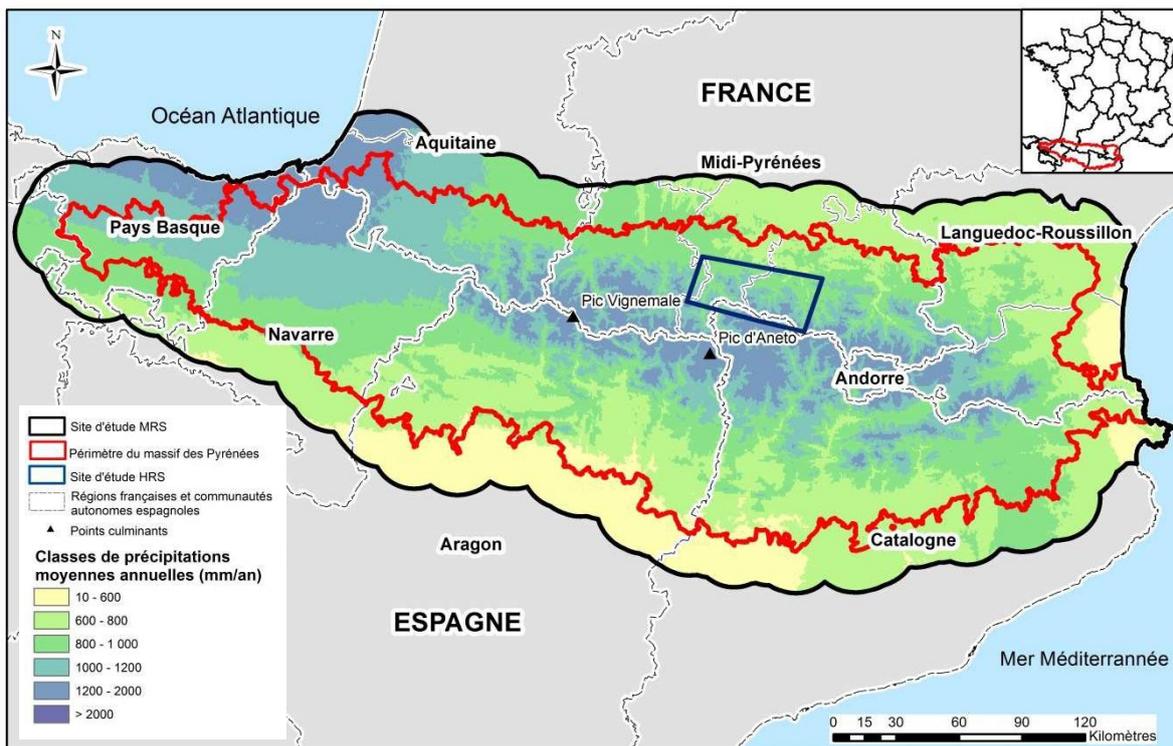


Figure 8 : Précipitations moyennes annuelles (mm/an) du site d'étude de 1950 à 2000 (source : <http://www.worldclim.org/current>).

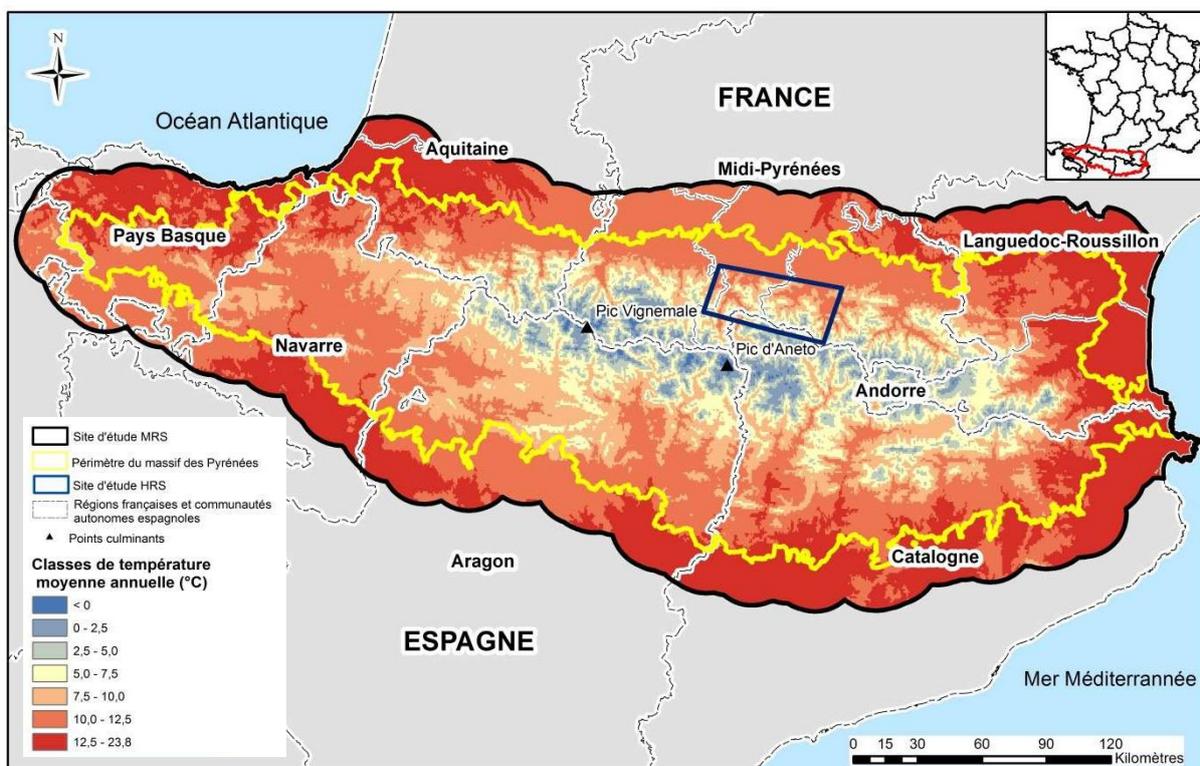


Figure 9 : Températures moyennes annuelles (°C) du site d'étude de 1950 à 2000 (source : <http://www.worldclim.org/current>).

1.1.3 Principales caractéristiques de la végétation

Le massif des Pyrénées présente un couvert forestier sur environ 43% de sa surface, qui devient le mode d'occupation du sol dominant entre 600 m et 2000 m d'altitude (figure 10). Sa répartition et sa densité diffèrent du versant Nord au versant Sud. La forêt des Pyrénées françaises est concentrée au cœur du massif et devient plus parsemée dans les montagnes basques et catalanes, dont le taux de boisement, inférieur à 25%, souligne la prépondérance de l'activité pastorale. Côté espagnol, une tendance inverse est observée, avec un couvert forestier plus important dans les montagnes navarroise et catalane qu'au centre du massif, du fait de politiques de reboisement. Le taux de boisement atteint 82% en Navarre et seulement 38% en Andorre.

La grande variabilité topographique et climatique de la chaîne pyrénéenne définit une mosaïque de milieux différents. Ce contexte induit une distribution spatiale complexe de la végétation sur l'ensemble du massif (Alcaraz-Segura et al., 2006). La composition en essences des peuplements forestiers du site d'étude présente une différenciation en étages, liée au gradient altitudinal et à l'effet des versants.

L'étage collinéen

L'étage collinéen se situe entre le niveau de la mer et 900 m. Il englobe l'ensemble des zones forestières du piémont et correspond, de façon théorique, à la limite supérieure des peuplements de chênes (Rameau et al., 2008). La forêt est composée majoritairement d'espèces caducifoliées. Les essences prépondérantes diffèrent selon les caractéristiques climatiques.

Ainsi, sous influence océanique, pour la montagne navarro-béarnaise de la partie Ouest du site d'étude, le couvert est dominé par le hêtre (*Fagus sylvatica*), accompagné de chênes caducs. C'est le cas des peuplements collinéens de Navarre, présentant la surface de hêtraie la plus importante de la péninsule (environ 135 000 ha), ainsi que des chênaies sèches à chêne pubescent (OPCC et CTP, 2013). A l'extrémité Sud-Ouest du site d'étude, la zone littorale du pays basque espagnol se singularise et présente une grande étendue de pins de Monterey (*Pinus radiata*), issue de reboisements. Les forêts du pays basque français se caractérisent, quant à elles, par la dominance de feuillus caducifoliés en mélange (chênes pédonculés et sessiles, hêtres, charmes et localement châtaigniers). La hêtraie devient prépondérante à proximité et au-delà des 900 m d'altitude, marquant la limite supérieure de l'étage. Cette tendance en versant Nord reste homogène et s'étend vers l'Est sur tout l'étage collinéen, jusqu'à l'Aude occidentale qui subit l'influence du climat subocéanique.

L'étage collinéen de la bordure Sud du site d'étude (Aragon et Catalogne) présente une surface limitée et morcelée du fait de l'abondance d'espaces dédiés au pastoralisme. Du fait du climat subcontinental à tendance méditerranéenne, impliquant des hivers rigoureux et parfois des sécheresses estivales, le hêtre est absent. Les forêts de chênes pubescents et sessiles sont présentes jusqu'à environ 600 m d'altitude, rapidement remplacées par le pin sylvestre (*Pinus sylvestris*) et des forêts mixtes de feuillus et de conifères, en raison d'importants reboisements ayant été réalisés sur la frange pré-pyrénéenne. On note, dans la zone d'influence méditerranéenne localisée dans l'extrême Sud du site d'étude, la dominance de peuplements de chênes verts (*Quercus ilex*) et de mélanges de chênes sempervirents.

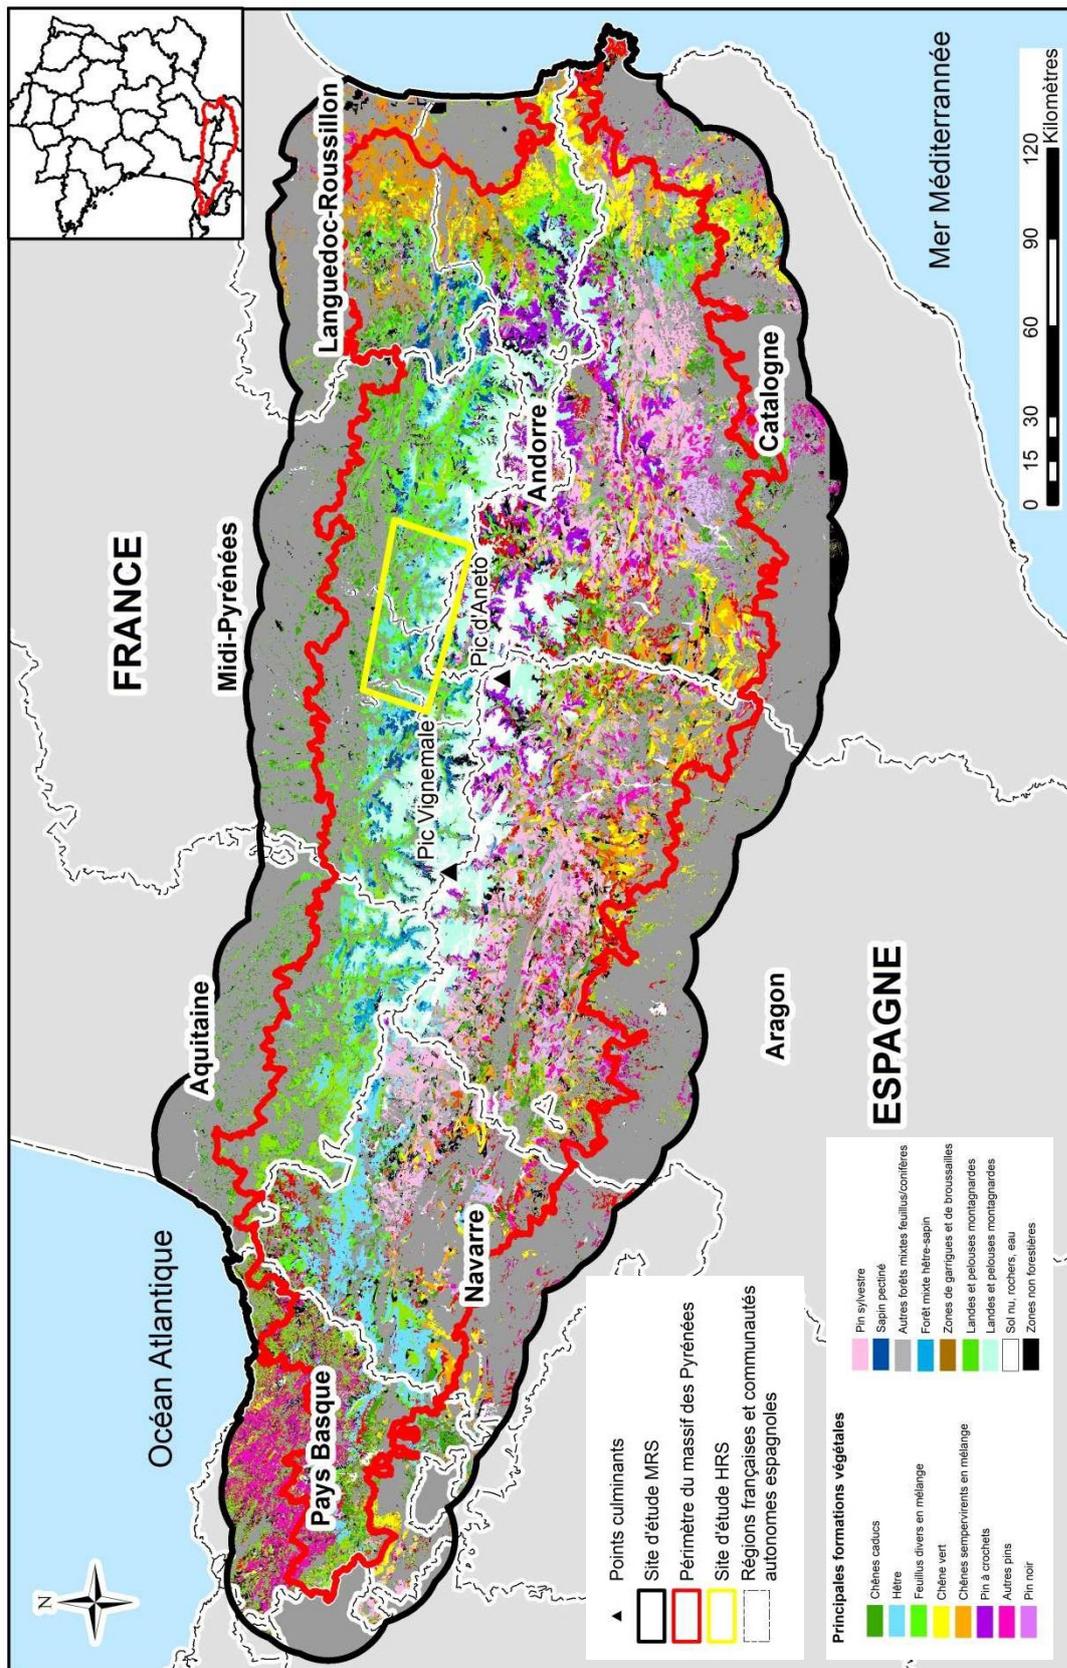


Figure 10 : Principales formations végétales du site d'étude MRS (sources : IGN, MFE50, MFA).

Dans la frange Est du site d'étude (Catalogne et Languedoc-Roussillon) l'étage collinéen est présent sous une forme périméditerranéenne ibéro-provençale. Les peuplements se composent de mélanges de feuillus : chênes pubescents, chênes sessiles, châtaigniers, hêtres (figure 11). En-dessous de 600 m et jusqu'au littoral, les peuplements de chênes verts, chênes sempervirents en mélange et les garrigues deviennent dominants.



Figure 11 : Hêtre (à gauche) et chêne sessile (à droite). Crédits : J.M. Savoie, EI-Purpan.

L'étage montagnard

L'étage montagnard se situe entre 900 m et 1500 à 1700 m. Il concerne une grande partie de la moyenne montagne française et espagnole. La composition en essences du couvert forestier est très contrastée entre les versants Nord et Sud.

L'étage montagnard français, sous influence subocéanique, se caractérise par une dominance des hêtraies et des forêts mixtes de hêtres et de conifères, dont le sapin pectiné (*Abies alba*), également présent, plus en altitude, en peuplements purs (Daubet et al., 2007). Ces caractéristiques se retrouvent de façon homogène sur l'ensemble de l'étage montagnard du versant Nord, de la pointe Sud-Est de l'Aquitaine à la frange Ouest du Languedoc-Roussillon.

L'étage montagnard espagnol, sous influence subcontinentale à tendance méditerranéenne, présente des conditions beaucoup plus sèches que le versant Nord. Il est de ce fait largement dominé par les peuplements de pins sylvestres, de l'extrémité nord-est de la Navarre à la Catalogne. Comme dans le cas de l'étage collinéen, le hêtre est absent. Le pin noir (*Pinus nigra*) est également présent dans les peuplements de Catalogne et le pin d'Alep (*Pinus halepensis*) sur l'ensemble de l'étage du versant sud. Dans la zone à tendance méditerranéenne située entre l'Aragon et la Catalogne, les pinèdes cèdent la place aux chênes verts et au mélange de chênes sempervirents.

Dans la frange Est du site d'étude (Languedoc-Roussillon et Catalogne), l'étage montagnard est caractérisé à nouveau par les peuplements de hêtres, de forêts mixtes et de sapins pectinés déjà observés pour le versant français avec une transition, à mesure qu'on se dirige vers le Sud, vers les peuplements de pins sylvestres (figure 12).



Figure 12 : Sapin pectiné (à gauche) et pin sylvestre (à droite). Crédits : J.M. Savoie, EI-Purpan.

L'étage subalpin

L'étage subalpin se situe entre 1500 m et 2200 m. Il englobe les derniers espaces forestiers d'altitude. Au-dessus de la limite supérieure de l'étage subalpin, les boisements ont disparu, laissant la place aux milieux ouverts. Les boisements marquant la limite forestière sont dominés par le pin à crochets (*Pinus uncinata*) en territoire espagnol (figure 13). L'essence dominante du versant Nord est le sapin pectiné, en peuplement purs ou, en limite inférieure, en mélange avec le hêtre. Elle est également sporadiquement présente en Navarre et en Aragon.

Au-delà de 2 000 à 2 500 m environ, les contraintes climatiques deviennent telles que la croissance des arbres et les arbustes n'est plus possible. Dès lors que cette limite potentielle forestière est dépassée, on observe, pour le versant Nord comme pour le versant Sud, une végétation caractérisée par des pelouses continues.

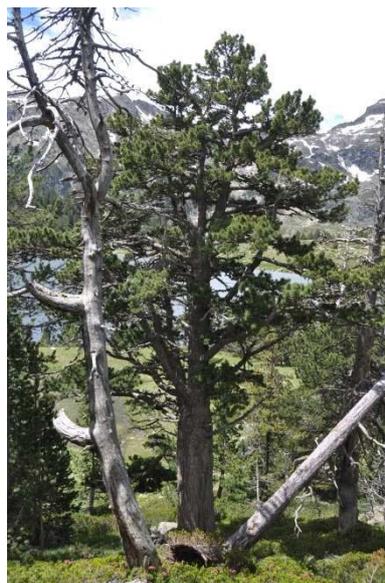


Figure 13 : Pin à crochets. Crédits : J.M. Savoie, EI-Purpan.

L'étage alpin

Délimité entre la limite supérieure de l'étage subalpin et 3000 m, l'étage alpin est caractérisé par une absence totale de formations boisées et par la présence des formations de landes et pelouses alpines (figure 14). Du fait des contraintes climatiques particulièrement sévères à ces altitudes (froid intense, alternance gel/dégel, vents violents), la végétation se trouve souvent discontinue, en alternance avec le sol nu ou la roche. La période de végétation y est inférieure à 100 jours par an.



Figure 14 : Lande alpine (à gauche) et alternance de pelouse alpine et de sol nu (à droite). Crédits : J.M. Savoie, EI-Purpan.

L'étage nival

Défini à partir de 3000 m d'altitude, il correspond à la zone d'enneigement persistant toute l'année. Les roches et les glaciers dominent (figure 15). Les seules traces de végétation prennent la forme de mousses et de lichens.



Figure 15 : Glacier de la Maladeta (versant espagnol). Crédits : J.M. Savoie, EI-Purpan.

1.2 Site d'étude HRS

Pour l'étude des données à haute résolution spatiale, on a souhaité s'intéresser à un site d'étude restreint, présentant une végétation représentative du massif montagneux des Pyrénées et dont la distribution spatiale n'est pas trop complexe. Le site d'étude HRS retenu a été défini en fonction de l'emprise des images à haute résolution spatiale à traiter. Il est intégralement situé sur le versant français, présente des formations végétales emblématiques de ce versant, telles que le hêtre, le sapin pectiné et la forêt mixte à hêtre et sapin. La végétation est organisée en étages bien définis et la taille

du site d'étude est suffisamment importante pour inclure une transition de végétation complète, jusqu'à l'étage nival.

1.2.1 Caractéristiques géographiques

Le site d'étude HRS est situé sur le versant pyrénéen français, dans les Pyrénées centrales (figure 16) et sur la zone frontalière espagnole (Catalogne). D'une superficie approximative de 145 000 ha, il s'étend sur les départements de l'Ariège (Haut-Couserans), des Hautes-Pyrénées et de la Haute-Garonne (Haut-Comminges). Sa limite Nord se situe au niveau des localités d'Aspet et de St Girons.

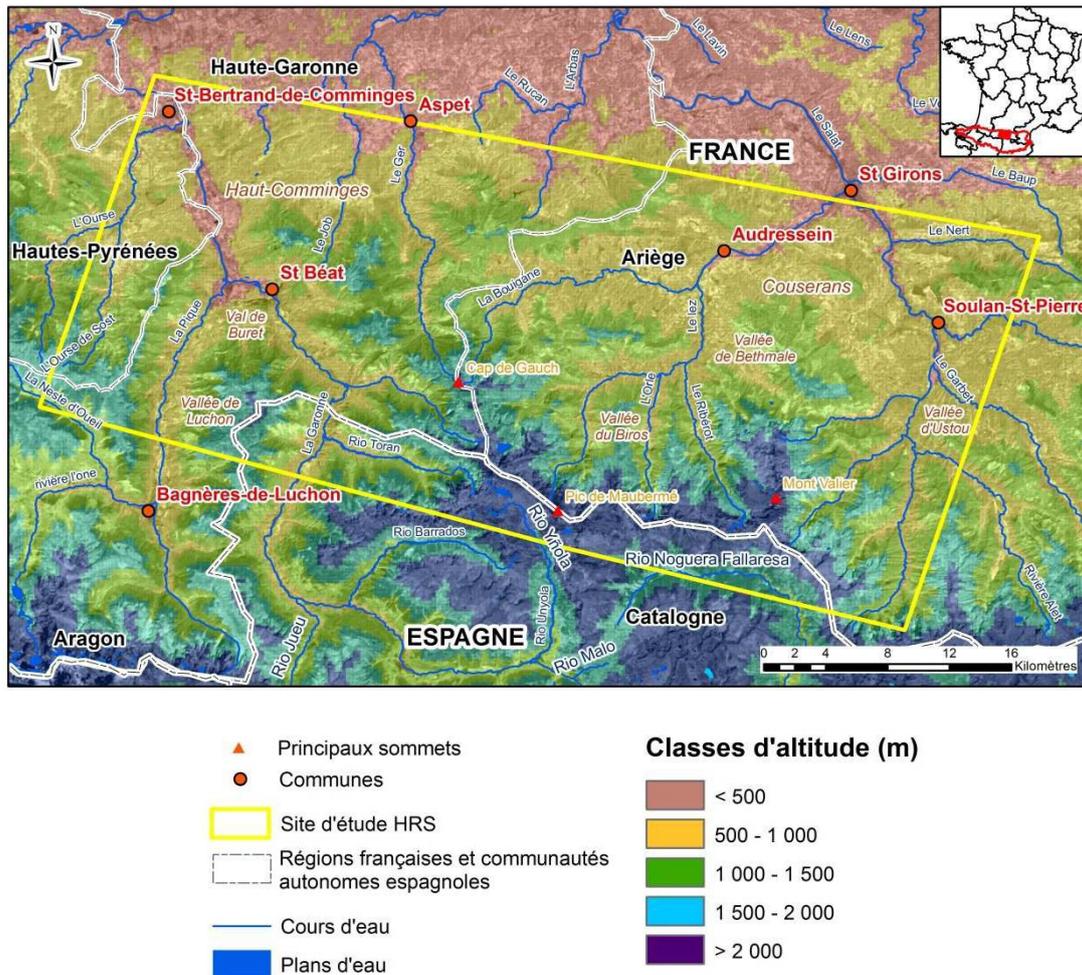


Figure 16: Localisation du site d'étude HRS (sources : GEOFLA (IGN), IFN (IGN), BD CARTHAGE, SRTM, MFE50).

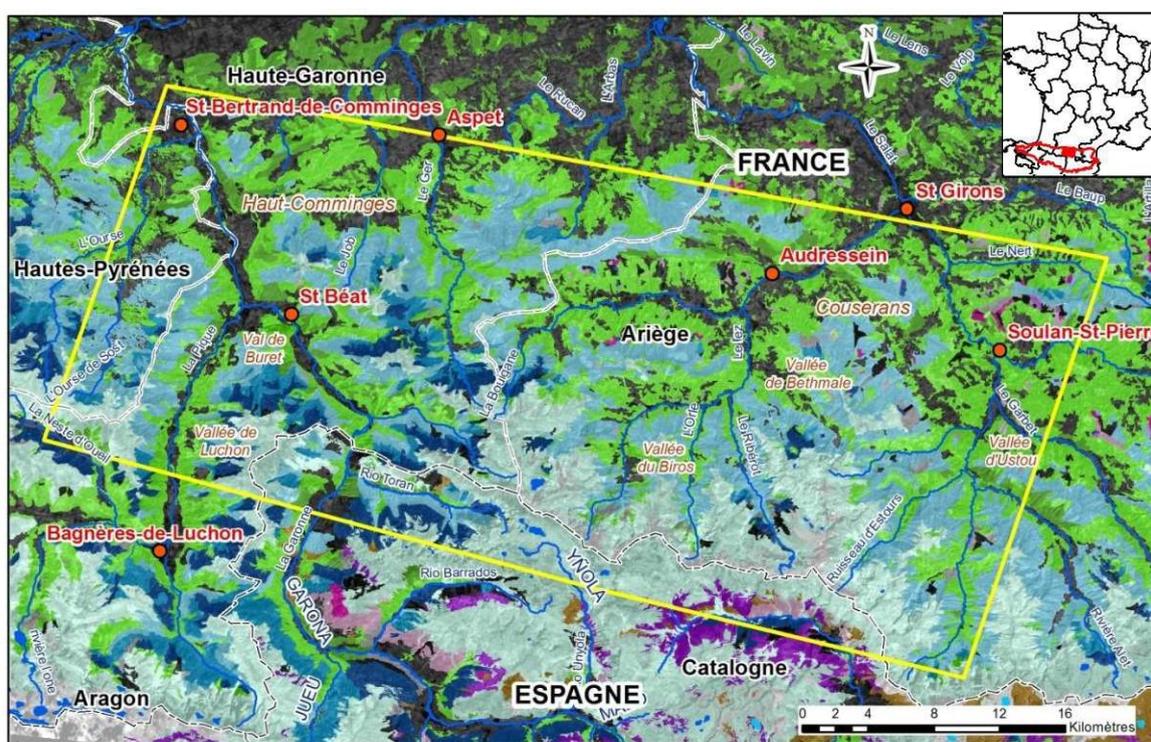
Le Haut-Comminges représente la partie la plus basse en altitude du site d'étude. Il est traversé entre 500 et 1500 m d'altitude par la vallée de la Pique, qui passe à Bagnères-de-Luchon (611 m) et conflue avec la Garonne à proximité de St Bât (476 m). Cette dernière poursuit sa course dans le piémont jusqu'à St Bertrand de Comminges (421 m). Plus à l'Est, le Haut-Comminges est traversé par la vallée du Ger, prenant sa source non loin du Cap de Gauch (2148 m).

Le Haut-Couserans se caractérise par un relief nettement plus accidenté. Au Sud, les hauts reliefs présentent de nombreux lacs d'altitude, ainsi que plusieurs sommets sur la ligne de crête séparant le

versant Nord du versant Sud, dont le Mont Valier (2838 m) et le pic de Maubermé (2880 m). La moyenne montagne du Haut-Couserans est structurée par un réseau hydrographique dense. Les deux principaux cours d'eau, le Salat et le Lez, sont alimentés par plusieurs affluents, notamment l'Arac et la Bouigane. Deux autres vallées importantes sillonnent le Haut-Couserans, les vallées du Garbet et de l'Ustou.

1.2.2 Caractéristiques des peuplements forestiers

Les vallées du Haut-Couserans et du Haut-Comminges présentent un gradient de végétation qui évolue progressivement de la chênaie aux feuillus en mélange et à la hêtraie, puis de la hêtraie à la forêt mixte hêtre-sapin, jusqu'à des peuplements de sapin pectiné, marquant la limite haute de la végétation forestière (figure 17). Les sapinières sont particulièrement bien développées dans le Luchonnais alors qu'elles sont plus limitées dans le Haut-Couserans. Les boisements laissent ensuite place aux milieux ouverts d'altitude : landes et pelouses alpines. Côté espagnol, ce sont essentiellement des landes et des pelouses alpines qui sont représentées. On distingue quelques boisements de pin à crochets et de pin sylvestre. La présence de ces essences traduit les différences d'exposition et de climat entre les deux versants en termes de températures et de précipitations.



Principales formations végétales



Figure 17: Principales formations végétales du site d'étude HRS (sources : GEOFLA (IGN), IFN (IGN), BD CARTHAGE, MFE50).

2 Les données

2.1 Données satellitaires

2.1.1 Données à moyenne résolution spatiale

Présentation des données

Les données satellitaires à moyenne résolution spatiale utilisées sont issues du capteur MODIS, embarqué à bord du satellite Terra. Son orbite est héliosynchrone polaire basse (705 km). Le capteur MODIS couvre ainsi l'ensemble du globe tous les jours au nord de 30° de latitude et tous les deux jours entre 30° nord et 30° sud, ce qui lui permet de réaliser des acquisitions systématiques quasi-journalières avec une fauchée d'environ 2300 km. Sur le plan spectral, le capteur MODIS enregistre de l'information dans un large domaine de longueurs d'ondes comprises entre 0,4 μm et 14,4 μm (36 bandes spectrales réparties sur le visible, le proche infrarouge, le moyen infrarouge et l'infrarouge thermique). La résolution spatiale des données est de moyenne à faible, variant entre 250 m et 1 km selon les bandes spectrales. Les données MODIS sont acquises quotidiennement depuis février 2000 et disponibles gratuitement. Elles peuvent être fournies sous la forme de synthèses établies sur 8 ou 16 jours. Les synthèses sont obtenues par la méthode du Maximum Value Composite ou MVC (Holben, 1986) qui consiste, pour chaque pixel, à prendre la valeur la plus élevée sur la période considérée et pour laquelle l'angle de vue est le plus proche du nadir. Cette méthode permet de s'affranchir des perturbations atmosphériques (nuages).

Le travail repose sur l'utilisation du produit MODIS MOD13Q1 (tableau 3). Il comprend des images de réflectance de surface dans le bleu, le rouge, le proche infrarouge, et le moyen infra-rouge, corrigées vis-à-vis des effets atmosphériques (diffusion moléculaire, absorption par l'ozone, effet des aérosols). Il comprend également des images d'indices de végétation (EVI et NDVI) calculés à partir des images de réflectance. La résolution spatiale de ces images est de 250 m. Les images ont été téléchargées à partir du serveur ftp du Land Processes Distributed Active Archive Center (LPDAAC) de l'USGS (United States Geological Survey), dont l'adresse est la suivante : <ftp://e4ft101.cr.usgs.gov/MOLT/MOD13Q1.005/>. Les données ont été mosaïquées selon un découpage régulier en tuiles carrées d'environ 1200 km de côté en projection sinusoïdale. Les sites d'étude sont couverts par les tuiles h17v04 et h18v04.

Tableau 3 : Caractéristiques des données du produit MOD13Q1 utilisées

Donnée	Résolution spatiale (m)	Longueur d'onde (μm)
NDVI – 23 synthèses de 16 jours par an	250 m	***
EVI – 23 synthèses de 16 jours par an	250 m	***
Réflectance R – 23 synthèses de 16 jours par an	250 m	0.620 - 0.670
Réflectance NIR – 23 synthèses de 16 jours par an	250 m	0.841 - 0.876
Réflectance MIR – 23 synthèses de 16 jours par an	500 m	2.105 - 2.155

Prétraitements

Les images ont été découpées à partir des deux tuiles pour couvrir le site d'étude, mosaïquées puis projetées selon la projection Lambert II étendue. Chaque image se compose ainsi de 2857 colonnes et de 1514 lignes et présente une étendue d'environ 660 km d'Est en Ouest et d'environ 352 km du Nord au Sud. Après prétraitement, la résolution des images est de 231 m.

Les images de réflectance n'ont pas fait l'objet de prétraitements complémentaires à la précorrrection atmosphérique MODIS.

Les images de NDVI et EVI ont en revanche été corrigées afin de remplacer les valeurs manquantes ou erronées liées aux périodes nuageuses et hivernales. La correction se base alors sur le cycle annuel de développement de la végétation, qu'on considère régulier d'une année sur l'autre. Une valeur d'EVI ou de NDVI peut ainsi être corrigée si elle apparaît incohérente par rapport à son cycle de variation sur l'année. Ce prétraitement, dénommé lissage, consiste tout d'abord à identifier les valeurs erronées et ensuite à les corriger. De nombreuses méthodes de lissage existent, certaines basées sur la cohérence par rapport à l'intégralité du cycle, d'autres basées sur le voisinage temporel de la valeur considérée (Pettorelli et al., 2005). La méthode de Savitzky-Golay, qui a été retenue ici, est basée sur le deuxième principe, qui permet de mieux prendre en compte les modifications interannuelles (Chen et al., 2004). Elle a été appliquée aux deux bases de données à l'aide du logiciel TIMESAT (Jönsson et Eklundh, 2004). Le lissage de Savitzky-Golay nécessite un paramétrage au préalable, relatif à la détection des pics et valeurs aberrantes et à la taille de la fenêtre de lissage. Dans notre cas, le seuil de détection des pics a été fixé à 0,3 et la taille de fenêtre à 5. Ces choix méthodologiques et ce paramétrage résultent d'une réflexion initialement menée pour la base de données de NDVI MODIS dans le cadre d'un autre travail de thèse (Lambert, 2014).

Trois bases de données d'images MODIS ont ainsi été constituées à partir du produit MOD13Q1, couvrant la période 2000-2014 :

- une base de données de réflectance dans le rouge (R), le proche infrarouge (NIR) et le moyen infrarouge (MIR), composée de 342 synthèses par bande spectrale soit au total 1026 synthèses de 16 jours. Cette base a été utilisée dans le cadre de la comparaison de trois méthodes de classification (chapitre IV),
- une base de données d'images de NDVI produite à partir des données de réflectance composée de 342 synthèses de 16 jours. Cette base a été exploitée pour la majeure partie des classifications réalisées dans le cadre des différents travaux (chapitres III, IV et V),
- une base de données d'images d'EVI produites à partir des données de réflectance, composée de 342 synthèses de 16 jours. Cette base a servi à la comparaison des trois méthodes de classification (chapitre IV), mais aussi à la réalisation d'une segmentation objet du site d'étude MRS (chapitre III).

A partir de ces bases de données images, différentes séries temporelles ont été construites et analysées. On pourra se reporter aux chapitres III et IV pour connaître leurs caractéristiques.

2.1.2 Données à haute résolution spatiale

L'objectif était de pouvoir disposer d'une série temporelle à haute résolution spatiale.

Les données à haute résolution spatiale utilisées dans le cadre des travaux de thèse proviennent du satellite Deimos-1. Son orbite est basse et héliosynchrone, à 686 km d'altitude. Il est équipé d'un capteur spectral permettant des acquisitions dans le vert (520-600 nm), le rouge (630 – 690 nm) et le proche infrarouge (770 – 900 nm) à une résolution spatiale de 22 m et sur 650 kilomètres de fauchée.

Il a été conçu pour assurer une couverture très fréquente de larges territoires, sa période de revisite étant de trois jours.

Le satellite Deimos-1 enregistre des images de réflectance de surface dans les bandes spectrales précédemment citées, ainsi qu'une bande synthétique additionnelle dans le bleu permettant de créer des images en couleurs naturelles. Trois types de produits existent :

- le produit L1R, composé du vert, du rouge et du proche infrarouge, sans traitement additionnel,
- le produit L1T, composé du vert, du rouge et du proche infrarouge et ortho rectifié à une précision inférieure au pixel Deimos (erreur quadratique moyenne de 10 m),
- le produit L1T en couleurs naturelles, comprenant la bande bleue de synthèse.

Tous les produits sont livrés dans la projection UTM/WGS84. Les produits disponibles permettent de réaliser des images de NDVI et d'EVI.

Nous avons pu disposer d'une série d'images acquises sur l'année 2013, couvrant une partie des Pyrénées (produit L1T). Des prétraitements géométriques et radiométriques ont été réalisés par le CESBIO. Au total 10 images sont disponibles et se distribuent sur une partie du cycle de végétation, de fin avril à fin septembre (tableau 4 et figure 18). Cependant 5 d'entre elles, soit ne couvrent pas complètement le site d'étude HRS, soit présentent une couverture nuageuse trop importante. Au final ce sont seulement 5 dates qui peuvent être exploitées. Elles se distribuent de manière trop irrégulière sur la saison de végétation pour considérer qu'elle constitue véritablement une série temporelle au sens présenté dans le chapitre I. On peut noter l'absence d'information sur la période printanière et sur la décroissance automnale.

Tableau 4 : Sélection, parmi les données disponibles, des images DEIMOS exploitables pour l'étude du site d'étude HRS.

Date d'acquisition	Couverture du site d'étude HRS	Nuages dans le site d'étude HRS	Image retenue pour constituer la base de données
24/04/2013	Complète	Non	Oui
07/07/2013	Incomplète	Oui	Non
08/07/2013	Complète	Oui	Non
20/07/2013	Incomplète	Oui	Non
21/07/2013	Incomplète	Oui	Non
30/07/2013	Complète	Non	Oui
12/08/2013	Complète	Oui	Non
22/08/2013	Complète	Non	Oui
04/09/2013	Complète	Non	Oui
23/09/2013	Complète	Non	Oui

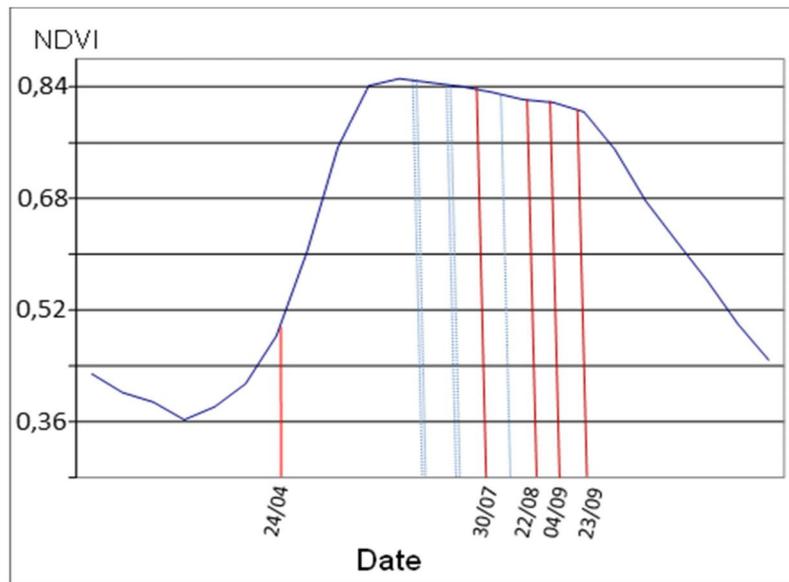


Figure 18 : Distribution des images Deimos sur le profil phénologique moyen du Hêtre (en rouge les dates retenues, en bleu les dates rejetées).

Les images ont été découpées selon l'étendue du site HRS, puis transformées selon la projection Lambert II étendue. Chaque image ainsi constituée a une taille de 3180 colonnes et de 2018 lignes. La résolution est de 22 m.

Deux bases de données à haute résolution spatiale, que nous nommerons données DEIMOS, ont été constituées pour ces 5 dates d'acquisition :

- une base de données d'images de réflectance de surface dans le vert (G), le rouge (R) et le proche infrarouge (NIR), composée de 15 images,
- une base de données d'images de NDVI, produites à partir de ces images de réflectance, composée de 5 images.

Des séries temporelles ont été constituées à partir de ces deux bases de données et exploitées dans le cadre de l'évaluation de l'apport d'une série temporelle à haute résolution spatiale (chapitre V).

2.2 Données ancillaires et complémentaires

Pour certaines classifications, l'ajout de données ancillaires a été testé.

La première donnée est l'altitude. Pour les classifications des séries temporelles MODIS, le plan d'altitude est issu du modèle numérique de terrain (MNT) de la base de données SRTM (Shuttle Radar Topography Mission). Il s'agit d'une version corrigée par CGIAR-CSI (Jarvis et al., 2008). La donnée initiale, qui est à environ 90 m de résolution, a été moyennée à 250 m à l'aide du logiciel ArcGIS. Pour les classifications des images DEIMOS, le modèle numérique de terrain utilisé est celui de l'IGN à 25 m de résolution spatiale (BD ALTI® V2).

La deuxième donnée est le rayonnement solaire global. Il a été calculé à partir des MNT précédemment cités, à l'aide du logiciel ArcGIS 10 (fonction de Spatial Analyst de calcul du rayonnement solaire zonal). Cette variable correspond au calcul pour chaque pixel de la quantité totale de rayonnement, elle est exprimée en W/m^2 . La méthode de calcul est basée sur l'algorithme du champ de vision hémisphérique développée par Rich (Fu et Rich, 2002 ; Rich et al., 1994). La latitude est celle qui est prise par défaut, soit $42,5^{\circ}N$, et la période de calcul s'étend sur l'ensemble de l'année.

Un masque des zones non forestières a été appliqué pour classer les séries temporelles d'images. Ce dernier correspond aux surfaces non renseignées (au sens de l'inventaire forestier national) ou renseignées comme zones urbaine ou agricoles dans les données de référence (carte forestière, voir partie 2.3.1.).

2.3 Données de référence et nomenclature forestière

2.3.1 Données de référence

Choix des sources

L'organisation des données de référence pour les sites d'étude MRS et HRS a été réalisée à partir des inventaires forestiers nationaux disponibles qui combinent une typologie de milieux naturels et semi-naturels et la cartographie des zones homogènes correspondant à cette typologie. Une base de données de référence a ainsi été construite pour l'ensemble du massif des Pyrénées à partir des inventaires forestiers nationaux suivants :

- pour la France, l'inventaire forestier de l'IGN, dont les années de collecte sont différentes selon les départements (de 1996 à 2001 dans le cas de la version 1, de 2006 à 2008 dans le cas de la version 2) (<http://inventaire-forestier.ign.fr/spip/>),
- pour l'Espagne, la Mapa Forestal de España (MFE 50), dont les inventaires ont été réalisés entre 2000 et 2005 pour les Communautés Autonomes concernées (<http://origin.magrama.gob.es/es/biodiversidad/servicios/banco-datos-naturaleza/informacion-disponible/mfe50.aspx>),
- pour l'Andorre, la Mapa Forestal del Principat d'Andorra (MFPA), révision de 2002 (<http://www.iea.ad/mapa-forestal-del-principat-d-andorra>).

Données IGN

La base de données de l'inventaire forestier de l'IGN est majoritairement constituée à partir de l'interprétation de photographies aériennes (BD Ortho en couleurs naturelles ou orthophotoplans de l'IGN réalisés à partir de photographies infrarouges pour la version 1, BD Ortho en infrarouge fausses couleurs pour la version 2). Le traitement de ces photographies est effectué en deux étapes successives :

- une étape de traitement semi-automatique, visant à extraire les contours des zones homogènes de l'image et à leur attribuer une classe d'occupation des sols. Elle consiste à appliquer une segmentation puis une classification avec apprentissage supervisé par objet (ou zone homogène),
- une étape de complément et de contrôle de l'information, consistant à détailler davantage la composition du couvert forestier et à la valider par des relevés de terrain.

L'inventaire est réalisé à l'échelle 1/25 000. La version la plus récente a été utilisée, c'est-à-dire la version 2 lorsqu'elle était disponible (tableau 5). Sur le plan sémantique, la base de données de l'IGN s'attache à caractériser les types de formations végétales. La définition fournie par l'IGN est la suivante (IGN, 2012 ; IGN, 2014) : « *un type de formation végétale est un ensemble forestier ou semi-naturel (landes, formations pastorales) continu ou discontinu, qui présente une certaine unité pour la couverture et l'utilisation du sol, pour la densité du couvert, pour la structure forestière et pour la composition en essences* ». Reconnue sur le plan international, cette définition a servi de base à l'établissement d'une classification cohérente à l'échelle mondiale de 225 types différents par la Food and Agriculture Organisation (FAO) en 1973. Les informations de la base de données de l'IGN décrivant les types de formations végétales ont été organisées selon plusieurs niveaux de nomenclature

emboîtés, différant selon la version de la base de données. La nomenclature de la version 1 distingue deux niveaux, le premier correspondant à la structure ainsi qu'à la composition majoritaire en feuillus ou conifères (ex : futaie de feuillus). Le deuxième précise la composition en essences des formations végétales.

Tableau 5 : Caractéristiques des données de l'IGN utilisées pour constituer la base de données de référence. V1 : version 1 de l'inventaire forestier, V2 : version 2 de l'inventaire forestier.

Département	Année d'acquisition des photos aériennes	Taille de l'unité de surface minimale cartographiée	Echelle	Date et version du document
09 – Ariège	2001	2.25 ha	1/25 000	2008 (V1)
11 – Aude	1999	2.25 ha	1/25 000	2004 (V1)
31 – Haute-Garonne	1996	2.25 ha	1/25 000	2004 (V1)
64 – Pyrénées-Atlantiques	2008	0.5 ha (2 ha essence pure)	1/25 000	2008 (V2)
65 – Hautes-Pyrénées	2006	0.5 ha (2 ha essence pure)	1/25 000	2006 (V2)
66 – Pyrénées-Orientales	1999	2.25 ha	1/25 000	2004 (V1)

La nomenclature de la version 2 est différente, structurée en 4 niveaux distincts. Le premier niveau distingue les zones de forêts des zones de landes. Le deuxième décrit la densité des couverts forestiers, distinguant notamment les forêts ouvertes (10 à 40% de couvert) des forêts fermées (plus de 40% de couvert). La structure et la composition majoritaire en feuillus et conifères des peuplements sont précisées dans le troisième niveau, équivalent au premier niveau de la version 1. Le dernier niveau détaille la composition en essences du couvert forestier. La surface minimale cartographiée varie entre 0,5 ha et 2 ha environ.

Données MFE50

La méthodologie de constitution de la base de données espagnole MFE50 est similaire à celle de l'IGN. Elle repose sur la photo-interprétation d'orthophotographies aériennes appartenant à chaque Communauté Autonome et la vectorisation à l'échelle 1/50 000 d'unités homogènes en termes d'occupation des sols (tableau 6). Les résultats ont été validés par des inventaires de terrain couvrant plus de 20% de la surface de chaque Communauté Autonome. La base de données est par ailleurs soumise à un contrôle de qualité interne et externe par un organisme indépendant. La méthode de caractérisation de la végétation consiste à délimiter des zones homogènes d'après leur type structurel (espace agricole, végétation naturelle non arborée, boisements, etc.). Les espaces de boisements présentent un niveau de détail descriptif supplémentaire, précisant notamment la proportion en surface des trois essences prépondérantes composant chaque zone homogène. L'intégralité des informations est en espagnol. La surface minimale cartographiée est de 6,25 ha pour les espaces naturels non forestiers et de 2,5 ha pour les boisements.

Tableau 6 : MFE50 (Mapa Forestal de España a escala 1 :50.000)

Région et provinces	Année du travail de terrain	Echelle de base	Date du document
Comunidad autónoma de Navarra	2000	1/50 000	3 ^{ème} inventaire
Comunidad autónoma del País Vasco	2005	1/50 000	
Comunidad autónoma de Aragón	2004	1/50 000	
Comunidad autónoma de Cataluña, provincia de Girona	2001	1/50 000	
Comunidad autónoma de Cataluña, provincia de Lleida	2001	1/50 000	

Données MFPA

La carte forestière d'Andorre a également été constituée par photo-interprétation d'orthophotographies aériennes, à l'échelle 1/5000 (tableau 7). Elle précise la structure et l'essence prépondérante de chaque zone homogène ainsi délimitée. L'intégralité des informations est en catalan. La surface minimale est de 500 m².

Tableau 7 : Mapa Forestal d'Andorra (MFPA)

Départements	Année d'acquisition des photos aériennes	Année du travail de terrain	Echelle de base	Date du document
Principat d'Andorra	1995	2002	1/5 000	2002

La date de la grande majorité des informations collectées correspond à la période couverte par les bases de données satellitaires à moyenne et haute résolution utilisées dans le cadre de la thèse. Ces données peuvent être combinées pour avoir une carte complète mais il est nécessaire d'harmoniser la dénomination et la définition des peuplements forestiers pour la nomenclature.

Harmonisation des informations des données de référence et constitution d'une cartographie forestière de référence

Du fait de la disparité des sources des données de référence, tant en termes de langue que de nature des informations descriptives du couvert forestier, un travail d'harmonisation s'est révélé nécessaire pour constituer une cartographie forestière exploitable pour la classification des séries temporelles d'images. Les résultats de ce travail d'harmonisation sont présentés en tableau 8. Une première étape a consisté à traduire l'ensemble des informations descriptives en français. Le travail d'harmonisation a ensuite consisté à obtenir une cartographie de référence du couvert forestier commune à l'ensemble des sites d'étude et adaptée au niveau de précision thématique souhaité. L'harmonisation a porté sur la nomenclature de cette cartographie forestière, tout en conservant les polygones délimités par les inventaires.

Pour rappel, les présents travaux de thèse visent à obtenir une cartographie classant la végétation forestière en zones homogènes selon l'essence ou le mélange d'essences prépondérant qui les composent. Si les méthodologies de caractérisation de la végétation diffèrent d'une donnée de référence à l'autre, les trois types d'inventaires ont pour information commune les essences prépondérantes des zones de boisements inventoriées.

Tableau 8 : Liste des formations végétales et de milieux naturels sans végétation pour le site d'étude MRS.

Niveau 1	Niveau 2	Niveau 1	Niveau 2
Feuillus caducs et divers	Chênes à feuillage caduc : Chêne pubescent : <i>Quercus pubescens</i> , Chêne pédonculé : <i>Quercus robur</i> , Chêne sessile : <i>Quercus petraea</i> , Chêne rouge d'Amérique : <i>Quercus rubra</i>	Forêt mixte	Forêt mixte : feuillus prépondérants et conifères
	Feuillus divers et indifférenciés (piémont)		Forêt mixte : conifères prépondérants et feuillus
	Feuillus divers et indifférenciés (montagne)		Forêt mixte : hêtre-sapin
	Feuillus divers et indifférenciés (méditerranée)		Forêt mixte : hêtre-pins
	Feuillus divers et indifférenciés (ripisylve)		Forêt mixte : conifères et feuillus à feuillage persistant
	Hêtre (<i>Fagus sylvatica</i>)		Forêt mixte : feuillus à feuillage caduc et persistant en mélange
	Châtaignier (<i>Castanea sativa</i>)		Forêt mixte : conifères et arbustes
Chênes sempervirents	Chêne tauzin (<i>Quercus pyrenaica</i>)	Garrigue et formations arbustives	Forêt mixte indifférenciée
	Bouleaux		Garrigue ou maquis boisé de chêne pubescent ou châtaignier ou feuillus indifférenciés
	Peupliers		Garrigue ou maquis boisé de chêne vert, chêne liège
	Eucalyptus		Garrigue ou maquis boisé de conifères indifférenciés
	Autres feuillus		Garrigue ou maquis non boisé
	Chêne liège (<i>Quercus suber</i>)		Broussaille à genévrier
	Chêne vert (<i>Quercus ilex</i>)		Broussaille à buis
Chêne faginé (<i>Quercus faginea</i>)	Matorral		
Chênes sempervirents indifférenciés ou en mélange	Matorral montagnard		
Chênes sempervirents indifférenciés et formations arbustives en mélange	Formations arbustives indifférenciées		
Conifères	Pin à crochets (<i>Pinus uncinata</i>)	Landes et formations herbacées	Pelouse, prairie
	Pin d'Alep (<i>Pinus halepensis</i>)		Grande lande montagnarde
	Pin maritime (<i>Pinus pinaster</i>)		Lande alpine
	Pin noir (<i>Pinus nigra</i>)		Pelouse alpine
	Pin de Monterey (<i>Pinus radiata</i>)	Formations diverses	Pelouses et landes d'altitude
	Pin sylvestre (<i>Pinus sylvestris</i>)		Formations diverses (surface <200ha)
	Pins indifférenciés ou en mélange (<i>Pinus pinea</i> ...)	Milieu naturel sans végétation	Sol nu, rochers
	Sapin pectiné (<i>Abies alba</i>)		Neige, glace
	Mélèze (<i>Larix decidua</i>)		Eau
	Sapin de Douglas (<i>Pseudotsuga menziesii</i>)		
Autres conifères			

La formation végétale, unité descriptive de la végétation des inventaires de l'IGN, est basée sur cette information. L'harmonisation des nomenclatures a donc été réalisée à partir de cette unité.

Les classes de nomenclature identifiées par l'inventaire forestier pour la partie française et retenues comme référentiel ont été mises en cohérence avec celles des données espagnoles et d'Andorre. Les proportions d'essences prépondérantes fournies par la MFE50 et la carte forestière d'Andorre ont été exploitées pour constituer une dénomination commune des formations végétales du versant Sud du massif des Pyrénées cohérente pour l'ensemble des sites d'étude. D'un inventaire à l'autre, des regroupements ont été opérés selon la composition des formations identifiées, afin de garder une cohérence en fonction des espèces et non de la densité, de la structure ou de la hauteur des peuplements. Les délimitations spatiales des zones homogènes inventoriées ont été conservées à l'identique.

La cartographie forestière finale se compose de 12 formations de feuillus caducs, 6 formations de chênes sempervirents, 11 formations de conifères, 8 formations de forêts mixtes de feuillus et de conifères, 9 formations de garrigues et de végétation arbustive, 5 formations de landes et de végétation herbacée.

2.3.2 *Nomenclature pour les classifications*

Une nomenclature a été construite à partir de la cartographie forestière de référence, afin d'identifier les formations végétales -précédemment décrites- par télédétection (tableau 9). La nomenclature à élaborer à partir de la cartographie forestière de référence doit être basée sur une dénomination commune à la France, à l'Espagne et à l'Andorre. Une simplification de la cartographie forestière de référence a ainsi été réalisée. Pour cela, certaines formations végétales ont été éliminées ou regroupées, en prenant en compte un seuil de surface et des résultats obtenus par des essais de classification.

Les formations dont la surface représentait moins de 1% de la surface totale n'a pas été maintenue : peupliers, eucalyptus, bouleaux, chênes liège, sapins de Douglas, mélèzes, forêts mixtes hêtres-pins, et formations diverses. C'est également le cas des mélanges d'essences indifférenciés. Il s'agit des : feuillus divers et indifférenciés de ripisylve, formations arbustives indifférenciées, formations diverses comprenant les chênes sempervirents indifférenciés ou en mélange, les pins indifférenciés, l'ensemble des forêts mixtes à l'exception de la forêt hêtre-sapin, et les feuillus divers et indifférenciés de montagne. On affectera ces classes à des classes plus généralistes telles que les feuillus divers indifférenciés ou dans certains cas à des essences proches. La neige a également été exclue de la nomenclature et confondue avec le sol nu. La nomenclature forestière finale se compose de 24 classes, dont 22 formations végétales. Elle se compose de formations végétales suffisamment bien définies, étendues et représentatives pour une classification de la végétation à l'échelle régionale, comme à une échelle plus locale.

La combinaison des informations fournies par les trois inventaires permet de couvrir de façon quasi-exhaustive le site d'étude MRS, ce qui est très favorable pour l'obtention d'une bonne carte à l'échelle régionale. On est ainsi en mesure de disposer d'un effectif de pixels suffisant pour l'entraînement de la classification supervisée, ainsi que d'une répartition spatiale équilibrée de ces pixels au sein du site d'étude.

Tableau 9 : Nomenclature retenue pour les classifications.

Niveau 1	Niveau 2	Niveau 1	Niveau 2
Feuillus caducs et divers	Chênes à feuillage caduc : Chêne pubescent : <i>Quercus pubescens</i> , Chêne pédonculé : <i>Quercus robur</i> , Chêne sessile : <i>Quercus petraea</i> , Chêne rouge d'Amérique : <i>Quercus rubra</i>	Forêt mixte	Forêt mixte : hêtre-sapin
	Feuillus divers et indifférenciés (piémont et méditerranée)	Garrigue et formations arbustives	Garrigue ou maquis boisé de chêne vert, chêne liège
	Feuillus divers et indifférenciés (montagne)		Garrigue non boisée
	Hêtre (<i>Fagus sylvatica</i>)		Matorral
	Chêne tauzin (<i>Quercus pyrenaica</i>)		Matorral montagnard
Chênes sempervirents	Chêne vert (<i>Quercus ilex</i>)	Landes et formations herbacées	Grande lande montagnarde
	Chênes sempervirents en mélange		Prairie montagnarde
Conifères	Pin à crochets (<i>Pinus uncinata</i>)		
	Pin d'Alep (<i>Pinus halepensis</i>)		Pelouse alpine
	Pin noir (<i>Pinus nigra</i>)	Milieu naturel sans végétation	Sol nu, rochers
	Pin de Monterey (<i>Pinus radiata</i>)		Eau
	Pin sylvestre (<i>Pinus sylvestris</i>)		
	Sapin pectiné (<i>Abies alba</i>)		

Surface de traitement

Les pixels MODIS qui ont été traités sont ceux qui sont contenus à plus de 80% dans la carte forestière de référence. Les pixels classés correspondent aux formations végétales de la nomenclature forestière que l'on a définie, auxquelles s'ajoutent les surfaces de milieux naturels sans végétation.

Dans le cas des images DEIMOS, les pixels classés correspondent à seulement 6 classes de la nomenclature. Tous les pixels correspondant à ces surfaces ont été traités.

Données pour l'entraînement des classifications

C'est à partir de la donnée cartographique de référence et en utilisant la nomenclature précédemment définie qu'ont été construits les jeux d'entraînement pour les différentes classifications. Dans le cas des données MODIS, la prise en compte de la mixité des pixels est un point important. Il sera tenu compte de la proportion des classes contenues dans un pixel et en particulier de celle qui est majoritaire, appelée dans l'étude « classe majoritaire ». Dans l'illustration suivante (figure 19), on identifie par exemple les pixels dont la classe majoritaire est inférieure à un taux de 50%.

Pour la construction des jeux d'entraînement, il est nécessaire d'affecter une classe aux pixels mixtes. On attribuera la classe majoritaire et ne seront retenus pour l'entraînement que les pixels dont le taux de classe majoritaire est supérieur à 50%.

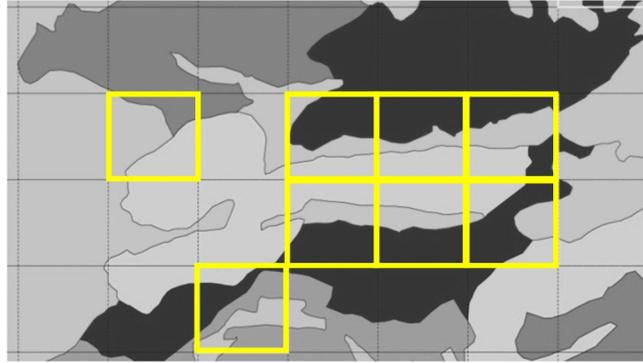


Figure 19 : Contour des pixels MODIS superposé à la carte de référence. En contour jaune, les pixels présentant un taux de classe majoritaire inférieur à 50%.

Pour les données DEIMOS, compte tenu de la résolution des images (22 m), la notion de mixité des pixels n'est pas prise en compte dans l'élaboration des données d'entraînement. Les pixels d'entraînement sont contenus à 100% dans les polygones de la carte de référence

2.4 Données de validation

2.4.1 Les données cartographiques

Comme pour l'entraînement, les jeux de validation ont été construits à partir de la donnée cartographique de référence.

Dans le cas des données MODIS, on utilisera les pixels dont la classe majoritaire est supérieure à 50%. Ces données couvrent une très forte proportion du territoire. Leur utilisation pour l'analyse spatiale de la qualité des résultats est un des points forts de l'étude

Pour les données DEIMOS, la notion de mixité des pixels n'est pas prise en compte dans la constitution des données de validation. Les pixels de validation sont contenus à 100% dans les polygones de la carte de référence.

2.4.2 Les données de placettes

Une deuxième source de données a été utilisée dans les procédures de validation. Il s'agit de relevés de terrain ponctuels réalisés sur des peuplements forestiers, dans le cadre de réseaux d'observation systématiques en France et en Espagne. En France, les mailles sont de 1km x 1km et les placettes d'inventaire sont choisies aléatoirement dans chaque maille. Chaque année, l'inventaire est réalisé sur 1/10 des placettes du réseau.

Une sélection de placettes a été réalisée. Pour l'Espagne, nous avons sélectionné les points d'une superficie d'au moins 0,1 ha, couverts à plus de 80% par de la forêt dans lesquels 15 à 25 arbres ont été inventoriés. Nous avons utilisé les inventaires des années 1999 et 2005. Pour la France, nous avons sélectionné les points inclus dans des massifs d'une superficie de plus de 4 ha, couverts à plus de 40% par la forêt. Nous avons utilisé les inventaires des années 2005 à 2013.

Parmi ces points, ont été retenus ceux ne présentant pas de changement entre les années 2000 et 2012 d'après la carte d'analyse de changement (Global Forest Change) produite par l'Université de Maryland (Hansen et al., 2013).

Un point important à souligner est que ces levés d'inventaire de peuplements forestiers ne concernent que 15 classes forestières sur les 24 classes de notre nomenclature. Au total, 2383 placettes sont ainsi localisées dans le site d'étude MRS, réparties au sein de chaque formation végétale (tableau 10). Pour le site HRS, le nombre de placettes utilisées pour la validation est de 95, dont 75 pour le hêtre, 12 pour le sapin pectiné et 8 pour la forêt mixte à hêtre et sapins.

Tableau 10: Placettes des inventaires forestiers France-Espagne.

Formation forestière	Nombre de placettes
Chênes à feuillage caduc	188
Feuillus divers et indifférenciés (piémont et montagne)	172
Feuillus divers et indifférenciés (méditerranée)	62
Hêtre	618
Chêne tauzin	69
Chêne vert	172
Chênes sempervirents en mélange	4
Pin à crochets	121
Pin d'Alep	11
Pin noir	98
Pin sylvestre	350
Pin de Monterey	373
Sapin pectiné	81
Forêt mixte hêtre-sapin	62
Garrigue ou maquis boisé de chêne vert, chêne liège	2
TOTAL	2383

Chapitre III : Evaluation de l'apport de la stratification à la classification par maximum de vraisemblance

1 Introduction

Ce chapitre porte sur l'amélioration d'une procédure de classification supervisée de séries temporelles d'images MRS à travers l'utilisation d'un procédé de stratification. En effet, parmi les éléments d'amélioration étudiés dans la littérature, il est reconnu que la stratification du site d'étude à traiter peut permettre d'augmenter la représentativité des signatures temporelles de la végétation par réduction de la variabilité spatiale des signatures (davantage de similarité interclasse et de variabilité intraclasse). Dans ce contexte, on a souhaité évaluer l'effet d'un tel procédé sur la qualité de classification d'images MODIS basée sur le maximum de vraisemblance. Cette approche de classification paramétrique et probabiliste a été choisie pour sa robustesse et son emploi courant pour des travaux de cartographie de la végétation. La cartographie de la végétation forestière du site d'étude MRS a été réalisée en appliquant une classification supervisée à deux séries temporelles de valeurs moyennées de NDVI dérivées des données MODIS. La stratification a été effectuée en appliquant aux images une segmentation orientée objet (OBIA) (Bisquet et al., 2015).

La démarche générale appliquée comprend 3 étapes (figure 20) :

- l'élaboration de la stratification du site d'étude MRS à partir des unités de paysage radiométriquement homogènes (HLU) obtenues par application de la méthode de segmentation orientée objet,
- l'évaluation de l'effet de la stratification sur la qualité de classification par comparaison des résultats obtenus avec et sans stratification,
- la recherche de critères utiles pour créer une stratification permettant d'améliorer les résultats de classification. Pour cela, l'influence des caractéristiques topographiques et paysagères sur les résultats a été étudiée.

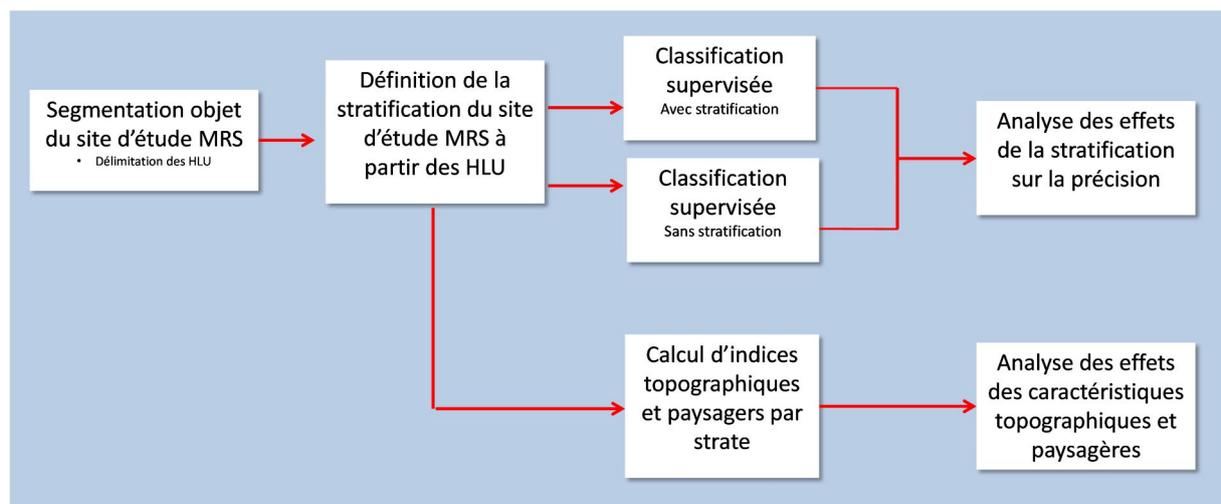


Figure 20 : Démarche générale.

2 Méthodes

2.1 Constitution des séries temporelles d'images

Deux séries temporelles ont été utilisées dans le cadre de cette étude, l'une pour la segmentation orientée objet du site d'étude MRS et la définition des strates, l'autre pour l'application de la classification supervisée.

Conformément à la méthodologie de segmentation orientée objet (OBIA) développée (Bisquert et al., 2015), le procédé de stratification a été basé sur l'utilisation d'une série temporelle MODIS d'EVI. Les synthèses sur 16 jours ont été combinées afin de produire une série de 12 images de moyenne mensuelle d'EVI sur la période 2007-2011. La durée de la série temporelle ainsi constituée permet d'éviter d'intégrer les effets qui pourraient être liés à une année atypique ou à des évolutions à plus long terme.

La classification supervisée a été appliquée à des séries temporelles MODIS de NDVI. Les images correspondant aux mois d'hiver (décembre, janvier et février) ont été éliminées de la série pour éviter d'intégrer des valeurs de NDVI aberrantes liées à l'influence du couvert neigeux. Deux séries temporelles ont été construites, chacune sur une durée de 3 ans, la première sur la même période que la stratification (2007-2009), la deuxième sur les 3 années suivantes (2009-2011). On a ainsi disposé pour la totalité de l'étude de deux séries de résultats comparables, afin de s'assurer de leur stabilité quelles que soient les années concernées. Pour les périodes, les synthèses de 16 jours ont été moyennées à la date, afin de produire deux séries temporelles de 17 images de NDVI moyen.

2.2 Délimitation des unités paysagères homogènes

La délimitation des unités paysagères homogènes (HLU) a été effectuée en utilisant une méthode de segmentation orientée objet basée sur l'identification de zones radiométriquement homogènes (Bisquert et al., 2015). L'objectif est de délimiter des HLU de dimension adaptée au site d'étude. La procédure consiste à identifier de façon objective :

- la meilleure combinaison d'indices pour intégrer leur caractéristique spectrale, texturale et temporelle,
- les meilleurs paramètres de segmentation des images à appliquer.

La méthode utilise la série temporelle des valeurs moyennes mensuelles d'EVI, calculées sur la période 2007-2011, et 5 indices de texture de Haralick (Haralick et al., 1973), calculés sur cette série d'images à l'aide du logiciel ENVI (*Exelis Visual Information Solutions, Boulder, Colorado*) : l'« homogénéité », le « contraste », la « dissimilarité », l'« entropie » et le « moment secondaire ». Pour leur calcul, une taille de fenêtre de 5 pixels a été utilisée. La segmentation objet est appliquée à l'aide du logiciel ECognition (*Trimble, München, Germany*). Au préalable, deux étapes d'optimisation de la procédure ont été mises en œuvre.

La première étape vise à diminuer le nombre de variables composant les données d'entrée de la segmentation (initialement 72 images : 12 images d'EVI + (12*5) images d'indices de texture). Pour cela, deux analyses en composantes principales successives ont été réalisées à l'aide du logiciel FactoMine R pour R (Lê et al., 2008). La première a été appliquée à l'ensemble des images mensuelles de chaque indice (EVI ou indice de texture), afin d'identifier les dates les plus représentatives. La deuxième a été appliquée à l'ensemble des indices (EVI ou indice de texture) pour chaque date retenue, afin d'analyser la corrélation entre ces indices. On a ainsi retenu les 3 dates les plus

représentatives à utiliser pour la segmentation et vérifié que les indices de textures sont peu corrélés aux données d'EVI.

La deuxième étape d'optimisation a pour objectif de choisir la meilleure combinaison EVI / indice de texture et d'optimiser le paramétrage de la segmentation. Cette optimisation concerne le critère d'homogénéité, qui a une influence directe sur la délimitation des HLU. Il est exprimé sous eCognition par le paramètre d'échelle, qui détermine l'hétérogénéité maximale des objets et conditionne donc la taille des segments obtenus. Pour cela, différentes segmentations ont été réalisées, basées sur la combinaison des données d'EVI et d'indices de texture :

- EVI + homogénéité,
- EVI + entropie,
- EVI + moment secondaire,
- EVI + contraste,
- EVI + dissimilarité.

Pour ce qui concerne le paramètre d'échelle, différentes valeurs ont été testées, par les auteurs, lors de l'application de la méthode de segmentation à l'ensemble du territoire français (Bisquert et al., 2015). Elles sont comprises entre 5 et 50 et cet intervalle de valeurs a été conservé pour la présente étude. Les segmentations ont été réalisées pour 10 valeurs du paramètre d'échelle comprises entre 5 et 50.

La meilleure combinaison et le paramètre d'échelle optimal ont été choisis à partir de deux méthodes d'évaluation non supervisée de ces segmentations, les méthodes respectives de Zhang (Zhang et al., 2012) et de Johnson (Johnson et Xie, 2011). La méthode de Zhang consiste à analyser la dissimilarité inter-segments en comparant chaque segment à l'image globale. La méthode de Johnson, complémentaire, consiste à évaluer la dissimilarité inter-segments en comparant les segments jointifs. Les segmentations ont été évaluées en calculant les deux indices statistiques, respectivement nommés indices Z (pour Zhang) et J (pour Johnson) (Bisquert et al., 2015). Pour chacune des 5 combinaisons étudiées, on obtient ainsi, en faisant varier la valeur du paramètre d'échelle entre 5 et 50, deux courbes d'évaluation distinctes. Le choix de la meilleure combinaison EVI/indice de texture est basé sur la forme de ces courbes. Pour une segmentation satisfaisante, on doit obtenir deux courbes diminuant progressivement jusqu'à l'atteinte d'un minimum, correspondant au paramètre d'échelle optimal, avant de croître. Les deux courbes d'indices Z et J doivent présenter ces évolutions de façon simultanée. Au final, on retient l'indice de texture pour lequel les deux courbes correspondent à la forme théorique optimale, la valeur optimale du paramètre d'échelle correspondant à leur minimum.

La délimitation des HLU dans le site d'étude MRS a été réalisée par une segmentation objet basée sur ces variables et paramètres.

2.3 Définition et caractérisation des strates

2.3.1 Définition des strates

Les HLU obtenues constituent l'ensemble des strates potentielles pour découper le site d'étude MRS. Les strates ont fait l'objet d'un premier essai de classification, ce qui a permis de constater que la procédure de classification ne peut pas être appliquée à certaines d'entre elles. Ces strates que l'on considère comme « strates critiques », présentent une surface forestière très faible avec une ou plusieurs classes de végétation d'effectif de pixels insuffisant. Le choix a été fait de fusionner ces « strates critiques » avec des strates contiguës, afin d'augmenter la surface forestière à classer et par conséquent l'effectif de pixels utilisés pour l'entraînement de la classification. Le critère de fusion est la similarité d'un point de vue de l'occupation des sols. Pour évaluer ce critère nous avons utilisé la base de données Corine Land Cover de 2006. Après extraction des proportions des différentes classes

d'occupation des sols, une valeur de corrélation de Spearman (Spearman, 1904) a été calculée pour chaque paire de strates contiguës. Il a été considéré qu'une « strate critique » pouvait être fusionnée avec sa voisine lorsqu'elle présentait une corrélation supérieure à +0,9. Les strates ne répondant pas à ce critère n'ont pas pu être fusionnées avec leurs voisines et n'ont pas été classées.

2.3.2 *Calcul d'indices descripteurs des strates*

Les strates obtenues ont été caractérisées à l'aide d'un ensemble de descripteurs de type topographique et paysager. Les 8 descripteurs ou indices retenus sont couramment employés en écologie du paysage (Forman et Godron, 1986 ; Turner, 1989 ; Turner, 1990). Calculés pour chacune des strates à partir du MNT ou des données forestières de référence, ils se répartissent en 3 catégories (tableau 11):

- des indices topographiques, qui rendent compte de la surface de la strate et du caractère plus ou moins montagneux et accidenté du relief, ce dernier ayant une influence directe sur la composition et l'organisation spatiale de la végétation,
- des indices surfaciques et d'organisation spatiale, qui caractérisent l'étendue du couvert forestier de la strate et la diversité des tailles des patches composant le couvert forestier,
- des indices de composition, dont l'indice de Shannon (Shannon, 1948), qui caractérisent la diversité des formations constituant le couvert forestier de la strate.

Plusieurs de ces indices reposent sur la notion de patch (Forman et Godron, 1981). Dans le cadre de cette étude, on considère qu'un patch correspond à un ensemble de pixels contigus appartenant à la même classe forestière. Les indices relatifs à l'aire des patches peuvent être considérés comme des indicateurs de la fragmentation du territoire auquel ils se rapportent.

Tableau 11 : Indices décrivant les caractéristiques topographiques et paysagères des strates.

INDICE	DESCRIPTION	EQUATION
INDICES TOPOGRAPHIQUES		
Surface de strate (ha)	Surface d'une strate (ha)	-
Altitude (écart-type)	Ecart-type des valeurs d'altitude dans une strate (m).	$\sqrt{\frac{\sum_{i,j} \left[e_{ij}^m - \left(\frac{E_m}{N} \right) \right]^2}{N}}$ <p>e_{ij}^m : ij altitude dans la strate E_m : Somme des valeurs d'altitude dans la strate N : Nombre de valeurs d'altitude dans la strate</p>
Pente (moyenne)	Valeur de pente moyenne dans une strate (°).	$\frac{S_m}{NS}$ <p>S_m : Somme des valeurs de pente dans la strate NS : Nombre de valeurs de pente dans la strate</p>
INDICES PAYSAGERS DE SURFACE		
Taux de couverture forestière totale	Taux de couverture forestière totale d'une strate (%).	$\frac{A_F}{A_S} * 100$ <p>A_F : Surface totale du couvert forestier (m²) A_S : Surface de la strate (m²)</p>
Aire de patch (moyenne)	Aire de patch moyenne pour une strate (hectares).	$\frac{A_S}{np} * \frac{1}{10000}$ <p>A_S : Surface de strate (m²) NP : Nombre de patches</p>
Aire de patch (écart-type)	Ecart-type de l'aire de patch dans une strate (hectares).	$\sqrt{\frac{\sum_{i,j} \left[a_{ij}^m - \left(\frac{A_S}{NP} \right) \right]^2}{NP}} * \frac{1}{10000}$ <p>a_{ij}^m : ij surface de patch (m²) A_S : Surface de strate (m²) NP : Nombre de patches</p>
INDICES PAYSAGERS DE COMPOSITION		
Nombre de classes	Nombre de classes pour chaque strate	-
Indice de diversité de Shannon	Indice indiquant la dispersion de la proportion en surface de chaque classe au sein d'une strate	$-\sum_i P_i * \ln(P_i)$ <p>P_i : Rapport entre la surface de la classe et la surface totale de toutes les classes</p>

2.4 Classification supervisée

La classification supervisée est appliquée aux deux séries temporelles de NDVI précédemment décrites, de périodes respectives 2007-2009 et 2009-2011. Chaque série est complétée du MNT du site d'étude MRS, utilisé comme donnée ancillaire.

L'algorithme de classification choisi, le maximum de vraisemblance, a été mise en œuvre à l'aide du logiciel ArcGis. L'algorithme du maximum de vraisemblance doit faire l'objet d'un paramétrage préalable à la classification supervisée. Deux paramètres doivent être ajustés :

- la pondération des probabilités d'appartenance à priori de chaque classe,
- le seuil de rejet.

Les probabilités d'appartenance de chaque classe correspondent pour un pixel donné à sa probabilité statistique d'appartenance à chaque classe de la nomenclature. Il est possible de choisir de pondérer ces probabilités préalablement à la classification. L'absence de pondération correspond à une équiprobabilité des classes. La pondération peut être estimée par rapport à l'étendue relative des classes au sein du site d'étude ou être proportionnelle au nombre d'échantillons propres à chaque classe. Pour la présente étude, aucune pondération n'a été appliquée et les classes sont équiprobables.

Le seuil de rejet correspond, pour un pixel donné, à la valeur seuil en dessous de laquelle le résultat de classification n'a plus de signification. Si la probabilité maximale d'appartenance du pixel est inférieure à ce seuil, alors aucune classe n'est définie pour ce dernier et il est considéré comme un pixel « mis en rejet » par la classification. Pour la présente étude, le seuil de rejet a été fixé à 0,01 (1%).

Les données de référence nécessaires à la classification ont été extraites de la cartographie forestière (chapitre II). Une nomenclature a ainsi été construite, composée de 22 formations végétales.

Afin d'évaluer l'apport de la stratification pour l'amélioration de la classification supervisée, cette dernière a été systématiquement appliquée avec et sans stratification aux deux séries temporelles de NDVI.

A la résolution des images MODIS, un nombre important de pixels couvrent des surfaces complexes. Ils sont situés sur des gradients de densité, des formations hétérogènes ou des bordures entre types de végétation. Les signatures de ces pixels mixtes sont souvent atypiques et demandent des traitements spécifiques. Il a donc été choisi de définir les pixels complètement inclus dans les limites des formations végétales comme les pixels à classer. Cette population de pixels représente environ 25% du site d'étude MRS et se compose de 196 591 pixels.

Le jeu d'entraînement a été obtenu par une sélection aléatoire à la strate et à la classe, répondant aux règles suivantes :

- pour un effectif de classe inférieur à 20 pixels, la classe n'est pas entraînée dans la strate correspondante,
- pour un effectif de classe de 20 à 40 pixels, la totalité de l'effectif est intégrée au jeu d'entraînement pour la strate,
- pour un effectif de classe compris entre 40 et 200 pixels, la moitié de l'effectif est sélectionnée aléatoirement et intégré au jeu d'entraînement pour la strate,
- pour un effectif de classe compris entre 200 et 2000 pixels, 20% de l'effectif est sélectionné aléatoirement et intégré au jeu d'entraînement pour la strate,
- pour un effectif de classe supérieur à 2000 pixels, 10% de l'effectif est sélectionné aléatoirement et intégré au jeu d'entraînement pour la strate.

L'effectif total du jeu d'entraînement est de 52 251 pixels et représente ainsi environ 26% des pixels à classer tels que définis précédemment.

Le jeu de validation est composé de la totalité des pixels à classer et contient donc le jeu d'entraînement. Pour chaque traitement, la matrice de confusion réalisée compare une classification (en lignes) aux données de référence correspondant à ce jeu de validation (en colonnes). Ces matrices ont permis d'évaluer la qualité des résultats de classification, par le calculer d'indicateurs. Deux indicateurs ont été retenus pour une analyse globale : l'indice de Kappa (Congalton, 1991 ; Foody, 2002 ; Stehman et Czaplewski, 1998), noté K, et le taux de rejet, noté TR, correspondant à la proportion de pixels à classer mis en rejet. La précision producteur est présentée pour une analyse détaillée par classe. Ces indicateurs ont été calculés et comparés pour les périodes 2007-2009 et 2009-2011, avec et sans stratification, à la strate et à l'échelle globale de la totalité du site d'étude MRS (tableau 12).

Tableau 12: Indicateurs d'évaluation de la qualité de classification.

Période	Classification	Indice de Kappa (K)	Taux de rejet (TR)	Précision producteur (PP)
2007-2009 2009-2011	sans stratification	Global	Global – (<i>par classe</i>)	Global – (<i>par classe</i>)
		Par strate	A la strate	
	avec stratification	Global	Global – (<i>par classe</i>)	Global – (<i>par classe</i>)
		Par strate	A la strate	
		Par strate	A la strate	

L'effet de la stratification sur les résultats de classification a été estimé en observant l'évolution de K et de TR par classe en analysant :

- l'évolution de la précision producteur (valeur et écart) de chaque classe avec la stratification (PP),
- la répartition du taux de rejet global entre les différentes classes.

2.5 Analyse de l'influence des caractéristiques topographiques et paysagères

On a cherché à mettre en évidence l'influence des caractéristiques des strates sur la qualité des classifications et de possibles effets de seuil. Pour cela, les 8 indices topographiques et paysagers calculés pour chaque strate ont été mis en relation avec les valeurs de K et de TR. Le coefficient de détermination r^2 de Pearson a été calculé pour caractériser cette relation, le seuil de significativité α étant de 0,05.

3 Résultats

3.1 Stratification

3.1.1 Délimitation des unités paysagères homogènes

La première ACP (ACP1) a été appliquée aux images d'EVI et d'indices de texture, afin de sélectionner les dates les plus représentatives. Les résultats obtenus pour l'ensemble des indices (exemple de l'EVI en figure 21/a) ont conduit à sélectionner les mois de janvier, avril et septembre. La deuxième ACP (ACP2) a donc été appliquée à l'ensemble des indices (EVI et indices de texture) correspondant aux trois mois retenus (exemple du mois d'avril en figure 21/b). Les résultats obtenus indiquent que l'« entropie » et la « dissimilarité » sont positivement corrélés, alors qu'ils sont négativement corrélés au « moment secondaire » et à l'« homogénéité ». Le « contraste » présente une corrélation faible avec l'ensemble des autres indices. L'EVI est faiblement corrélé à tous les indices de texture. Par conséquent, aucun indice de texture n'a été écarté de l'étude.

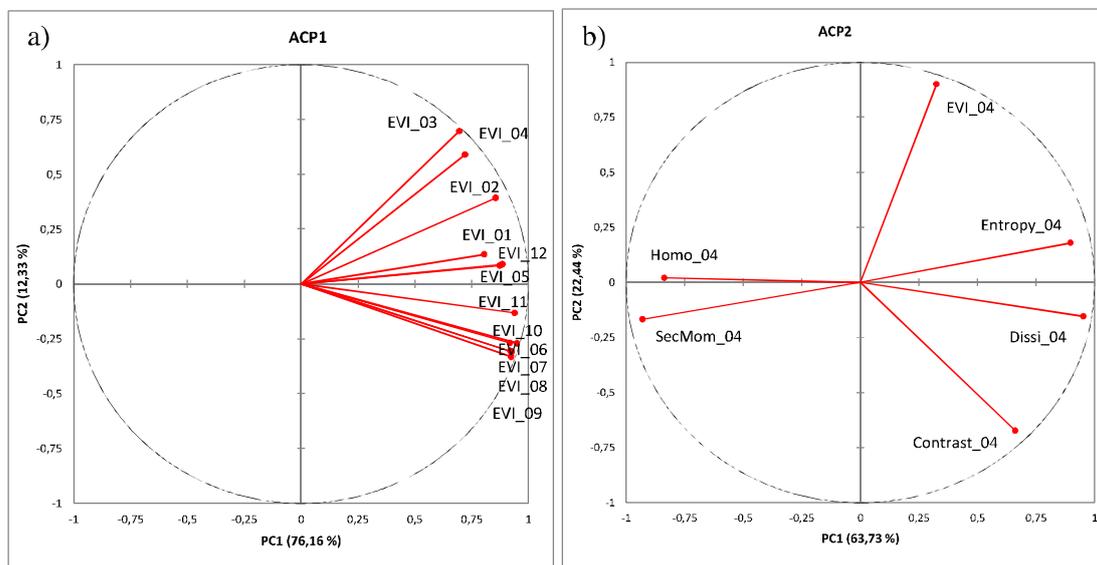


Figure 21 : Résultats de l'Analyse en Composantes Principales (ACP) : a) pour les deux premiers axes factoriels (PC1 et PC2) des séries temporelles d'EVI (EVI_mois) ; b) pour les deux premiers axes factoriels (PC1 et PC2) des 5 indices de texture (Dissi : dissimilarité ; SecMom : Moment Secondaire ; Homo : Homogénéité) et de l'EVI pour le mois d'avril (04).

La figure 22 présente les résultats obtenus à partir du calcul des indices Zhang et Johnson issus des méthodes d'évaluation non supervisée pour différentes valeurs du paramètre d'échelle. Les meilleurs résultats résultent de la combinaison de l'EVI et du moment secondaire. La courbe correspondante présente la forme optimale recherchée, une diminution des indices de Zhang et Johnson jusqu'à l'atteinte d'un minimum, suivie d'une augmentation (figure 22). La meilleure valeur du paramètre d'échelle est estimée entre 15 et 20, correspondant à la valeur minimale des 2 indices. Cette analyse aboutit ainsi aux mêmes conclusions que l'étude antérieure menée pour l'ensemble du territoire national (Bisquert et al., 2015). L'indice de texture "moment secondaire" et la valeur de 15 pour le paramètre d'échelle ont été retenus. Le découpage résultant est constitué de 56 HLU qui composeront le jeu de strates.

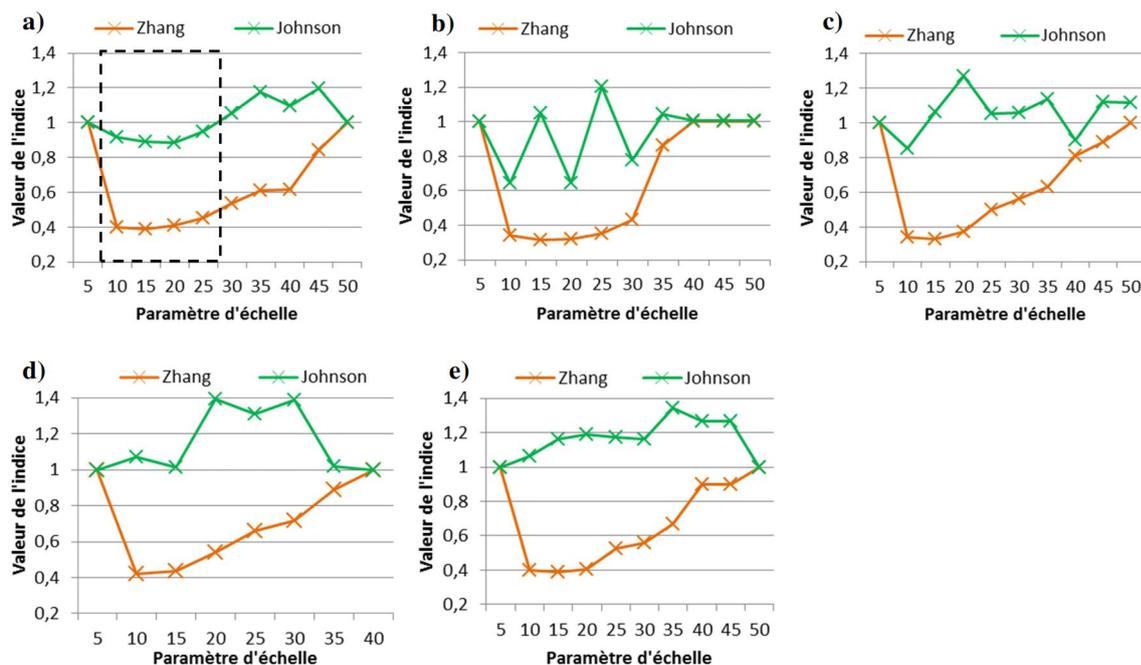


Figure 22: Résultats obtenus (courbes de Zhang et Johnson) à partir de trois dates d'EVI et pour chacun des 5 indices de texture moyennés sur une période de 5 ans (2007-2011) : a) moment secondaire, b) contraste, c) dissimilarité, d) homogénéité, et e) entropie.

3.1.2 Définition des strates

Parmi les 56 strates obtenues, 39 ont été identifiées comme des « strates critiques ». Parmi ces 39 strates, 27 ont pu être fusionnées avec leur voisine et 12 ont dû être éliminées de la zone d'étude (figure 23). Ces dernières sont localisées en zone de piémont, en limite basse du massif montagneux, et sont principalement occupées par des terres agricoles.

Au final, 25 strates composent le site d'étude MRS.

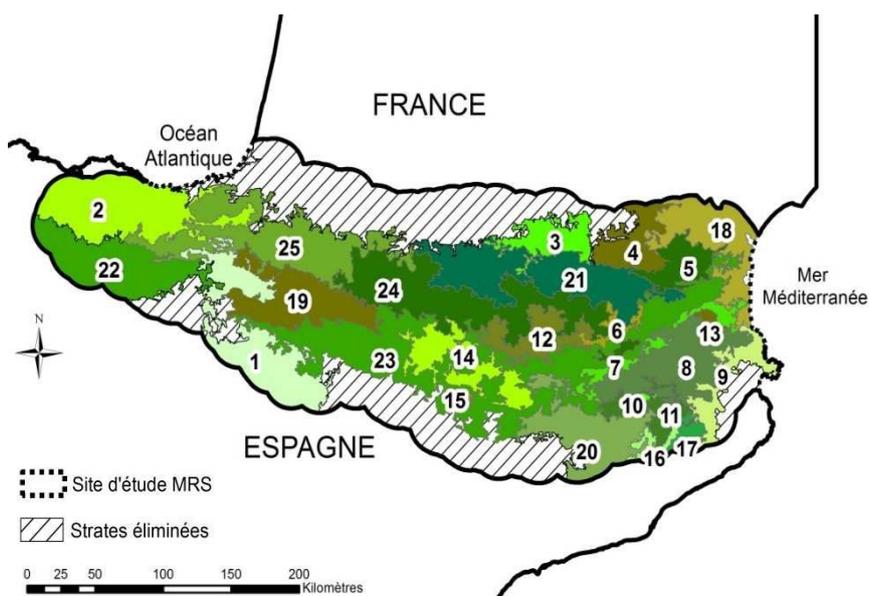


Figure 23: Stratification du site d'étude MRS obtenue après fusion et élimination des strates critiques. 25 strates sont délimitées.

3.1.3 Caractérisation des strates

Les valeurs des 8 indices topographiques et paysagers ont été calculées pour les 25 strates (tableau 13).

Tableau 13: Valeurs minimales, maximales et écart-type calculés par strate pour les 8 indices paysagers et topographiques.

INDICE	MIN.	MAX.	MOYENNE	ECART-TYPE
INDICES TOPOGRAPHIQUES				
Surface (ha)	13242	917244	240950	212307
Altitude (écart-type) (m)	100	543	257	127
Pente moyenne (degrés)	3	22	10	5
INDICES PAYSAGERS DE SURFACE				
Taux de couverture forestière totale (%)	29	92	71	20
Aire moyenne des patches (ha)	80	15715	3054	3543
Aire des patches (écart-type) (ha)	19	205	72	52
INDICES PAYSAGERS DE COMPOSITION				
Nombre de classes	3	23	11	6
Indice de diversité de Shannon	1,35	2,77	2,07	0,41

Les 25 strates obtenues sont en général orientées Est-Ouest, comme le massif montagneux, mais de forme et de dimension très variables, comme le montre la figure 23. La superficie de la plus grande strate du site d'étude représente près de 70 fois celle de la plus petite (tableau 13). Dans l'ensemble les valeurs des indicateurs montrent une très forte variabilité exprimant le caractère plus ou moins accidenté et montagneux des strates et l'importance de leur boisement.

3.2 Effet de la stratification sur la qualité des classifications

3.2.1 Analyse au niveau global

Les classifications supervisées ont été réalisées à l'échelle globale et par strate, pour les deux périodes étudiées. On peut constater une augmentation des valeurs de K lorsqu'on utilise la stratification, puisqu'elle passe de 0,53 à 0,64 et de 0,52 à 0,65 pour les deux périodes étudiées (tableau 14). Parallèlement, l'usage de la stratification se traduit par une augmentation de la valeur de TR, de 6 ou 7% selon la période considérée, à 13%.

Tableau 14: Evaluation au niveau global de la qualité de classification obtenue avec et sans stratification pour les deux périodes étudiées (indice de Kappa et taux de rejet).

Période	Classification	Indice de Kappa (K)	Taux de rejet (TR)
2007-2009	Sans stratification	Global: 0,53	Global: 6%
	Avec stratification	Global: 0,65	Global: 13%
2009-2011	Sans stratification	Global: 0,52	Global: 7%
	Avec stratification	Global: 0,64	Global: 13%

On observe donc que le recours à la stratification améliore la précision de la classification mais engendre une augmentation de la proportion de pixels non classés. Les résultats sont similaires pour les deux périodes d'observation. Cette constatation étant généralisée à l'ensemble des tests réalisés dans le cadre de cette étude, les résultats présentés ci-après porteront exclusivement sur la période 2007-2009.

Le tableau 15 présente les valeurs de la précision producteur de chaque classe pour les résultats de classification obtenus à l'échelle globale, avec et sans stratification. L'écart indiqué correspond à une différence arithmétique entre ces deux situations.

La stratification améliore les valeurs de précision producteur pour toutes les classes. La valeur augmente en moyenne de 15%, en passant de 51% à 66%. Les valeurs sont aussi moins dispersées, l'écart-type des valeurs de PP diminuant de 20% à 13%. La précision utilisateur présente des résultats similaires : la moyenne passe de 47% à 62% et l'écart-type de 21% à 13%. Cet effet n'est pas homogène pour toutes les classes. En triant les valeurs de différences de PP avec et sans stratification, on peut distinguer trois groupes de classes. Le premier groupe est celui pour lequel l'apport de la stratification est faible, 2% en moyenne. Il s'agit de classes initialement bien classées et qui progressent peu, ce sont des formations homogènes (hêtre, pin de Monterey).

Tableau 15: Effet de la stratification sur la précision producteur pour la période 2007-2009.

Classe	Précision producteur		
	Sans stratification	Avec stratification	Ecart
Hêtre	74%	75%	1%
Pelouse alpine	63%	64%	1%
Chêne vert	58%	59%	1%
Forêt mixte : hêtre – sapin pectiné	60%	63%	3%
Pin de Monterey	93%	96%	3%
Matorral	54%	60%	6%
Garrigue	70%	80%	10%
Pin d'Alep	61%	70%	10%
Pin à crochets	66%	77%	11%
Pin sylvestre	57%	69%	12%
Pin noir	52%	64%	12%
Lande alpine	54%	69%	15%
Feuillus divers et indifférenciés (Méditerranée)	55%	72%	16%
Prairie montagnarde	57%	74%	17%
Sapin pectiné	61%	79%	18%
Feuillus divers et indifférenciés (piémont, montagne)	20%	46%	26%
Matorral montagnard	24%	50%	26%
Garrigue boisée	13%	40%	27%
Grande lande montagnarde	38%	67%	29%
Chêne tauzin	40%	69%	29%
Chênes sempervirents	14%	48%	33%
Chênes à feuillage caduc	30%	64%	34%
Moyenne	51%	66%	
Ecart-type	20%	13%	

On trouve aussi des classes avec une PP satisfaisante (autour de 60%) mais qui ne progresse pas. Il s'agit des formations du chêne vert, du matorral, de la pelouse alpine et de la forêt mixte hêtre-sapin. Le second groupe présente des précisions utilisateur bonnes (de 52 à 70%) et une progression moyenne (+13%). C'est le cas de la plupart des formations de pins mais aussi de certaines formations basses (prairie, garrigue). Enfin, on peut remarquer que les valeurs initiales les plus faibles (inférieures à 40%) sont celles qui sont le plus améliorées par la stratification (+29% en moyenne). Avec la stratification, toutes les valeurs de PP deviennent supérieures à 40%. Ce groupe est formé majoritairement de classes hétérogènes, soit des mélanges d'essences (chênes caducs et sempervirents, feuillus divers), soit des mélanges de formations arborées et de formations basses (garrigue, matorral, pelouse alpine). L'analyse des matrices de confusion montre que les principales confusions sont observées entre des formations monospécifiques pour une essence donnée et les mélanges partiellement composés de ces mêmes essences. C'est par exemple le cas entre le sapin pectiné et la forêt mixte hêtre-sapin.

On observe que la répartition du rejet (fraction à la classe du rejet par rapport au rejet total) entre les différentes classes est similaire à celle de la surface de chaque classe dans la carte forestière de référence (tableau 16). On a précédemment vu que le gain de qualité thématique dû à la stratification s'accompagnait d'une augmentation de 6 à 7% du taux de rejet (TR). Cependant, lorsqu'on observe la répartition du rejet à la classe, cette dernière n'est pas modifiée, car cette hausse s'effectue de manière homogène pour toutes les classes.

Tableau 16 : Fraction de rejet par rapport au rejet total.

Classe	Surface dans la carte de référence (ha)	% de la surface à classer	Fraction de rejet par rapport au rejet total	
			Sans stratification	Avec stratification
Pin de Monterey	2 173	1%	2%	1%
Forêt mixte : hêtre - sapin	2 696	1%	2%	1%
Pin d'Alep	2 890	1%	1%	1%
Prairie montagnarde	2 985	2%	2%	2%
Chêne tauzin	3 352	2%	2%	2%
Sapin pectiné	4 159	2%	3%	3%
Grande lande montagnarde	4 771	2%	3%	2%
Matorral	4 910	2%	2%	2%
Matorral montagnard	5 958	3%	3%	3%
Chênes sempervirents	5 985	3%	2%	3%
Garrigue boisée	6 608	3%	3%	3%
Pin noir	7 037	4%	4%	3%
Chênes à feuillage caduc	7 497	4%	2%	3%
Garrigue	8 069	4%	6%	5%
Feuillus indifférenciés (piémont et montagne)	8 177	4%	3%	4%
Pin à crochets	8 943	5%	6%	5%
Feuillus indifférenciés (Méditerranée)	9 096	5%	2%	3%
Pelouse alpine	11 879	6%	4%	5%
Chêne vert	15 289	8%	5%	6%
Prairie alpine	23 013	12%	10%	9%
Hêtre	26 317	13%	13%	12%
Pin sylvestre	26 831	14%	14%	13%

3.2.2 Analyse par strate

On a vu que la stratification améliore globalement l'indice kappa mais en même temps augmente le rejet. Si cette progression est aussi vraie pour chaque strate analysée individuellement, on peut cependant observer des variations importantes de l'effet de la stratification sur les résultats de classification. La figure 24 montre que sans utilisation de la stratification les valeurs de kappa varient avec quelques valeurs faibles (5 strates ont un K inférieur à 0,3) et surtout une majorité de valeurs autour de la moyenne (0,53) : 20 strates sur 25 ont des valeurs entre 0,3 et 0,7. Le TR est peu dispersé autour de la moyenne (6%), seules deux strates ayant une valeur de TR supérieure à 10%. L'utilisation de la stratification améliore les valeurs de K de toutes les strates. La quasi-totalité des strates (23 sur 25) ont un K supérieur à 0,5. Cependant, on observe une augmentation de TR qui est pratiquement proportionnelle à celle de K. Les valeurs de rejet sont toutes supérieures à 10%. Malgré la valeur globale 13%, on remarque que 8 strates ont un TR supérieur à 20%.

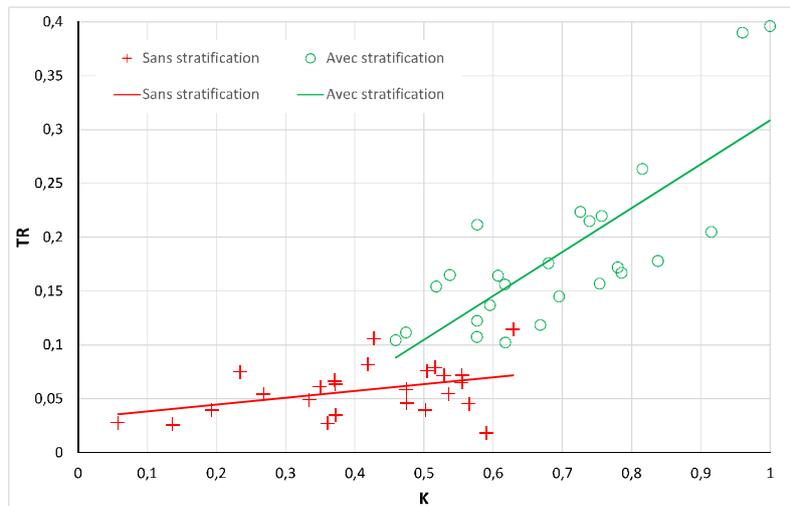


Figure 24: Relation entre valeurs de TR et valeurs de K pour les 25 strates avec et sans stratification et pour la période 2007-2009.

On constate à partir de l'ensemble des résultats précédents que les strates présentant les gains de K les plus importants sont également celles qui présentent les hausses de rejet les plus élevées. La figure 25, qui représente la relation entre écart de K et écart de TR, indique une corrélation hautement significative et positive entre ces deux indicateurs.

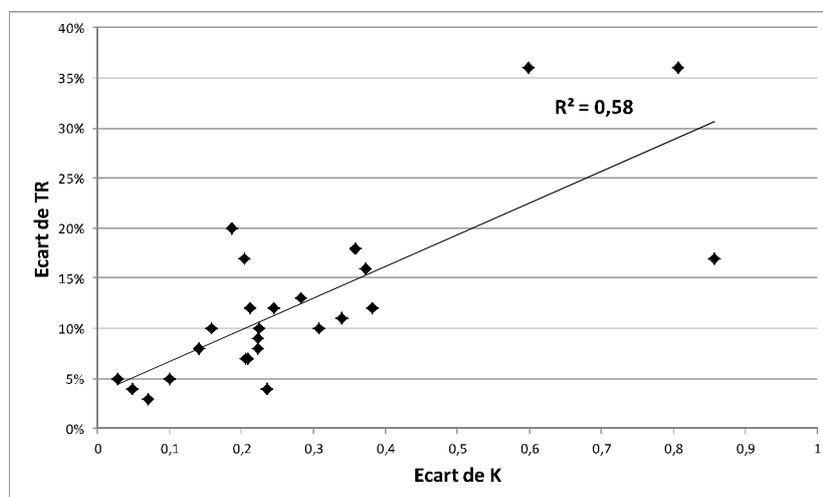


Figure 25: Relation entre écart de K et écart de TR pour les 25 strates et pour la période 2007-2009.

La répartition des valeurs de K (avec et sans stratification) en fonction de la surface des strates (figure 26) permet de visualiser trois ensembles de strates en fonction de leur surface. On identifie ainsi 3 seuils de surface, par interprétation visuelle de la distribution des résultats :

- les strates de petite surface, inférieure à 200 000 ha,
- les strates de très grande surface, supérieure à 450 000 ha,
- un ensemble intermédiaire de strates de surface comprise entre 200 000 et 450 000 ha.

Cette caractérisation des strates selon leur surface sera reprise dans les figures suivantes et va nous servir de base à l'interprétation des résultats suivants.

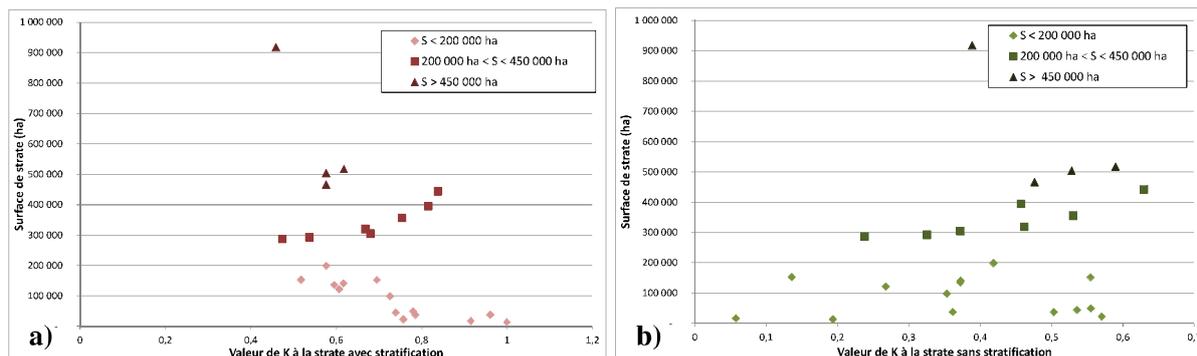


Figure 26 : a) Relation entre la valeur de K à la strate avec stratification et la surface de strate (ha) pour la période 2007-2009; b) Relation entre la valeur de K à la strate sans stratification et la surface de strate (ha) pour la période 2007-2009.

3.3 Analyse de l'influence des caractéristiques topographiques et paysagères des strates

Les corrélations de Pearson (valeurs de r^2) obtenues entre les indices descripteurs des strates et les valeurs et écarts de K et de TR permettent d'identifier l'influence de certains d'entre eux sur l'efficacité de la stratification (tableau 17). Rappelons qu'il a été constaté que les écarts de K et de TR liés à la stratification sont systématiquement des gains.

Tableau 17 : Corrélations de Pearson (r^2) entre les indices à la strate et les écarts de K et de TR pour la période 2007-2009 (grisé : corrélation significative pour $\alpha=0,01$; (+) : corrélation positive ; (-) : corrélation négative).

Indice	Ecart de K	Ecart de TR
INDICES TOPOGRAPHIQUES		
Surface de strate (ha)	(-) 0,32	(-) 0,35
Altitude (écart-type) (m)	(-) 0,38	(-) 0,31
Pente (moyenne) (degrés)	(-) 0,28	(-) 0,18
INDICES PAYSAGERS DE SURFACE		
Taux de couverture forestière totale	(-) 0,09	(-) 0,11
Aire des patches (moyenne) (ha)	(+) 0,07	(+) 0,003
Aire des patches (écart-type) (ha)	(+) 0,64	(+) 0,59
INDICES PAYSAGERS DE COMPOSITION		
Nombre de classes	(-) 0,34	(-) 0,42
Indice de diversité de Shannon	(-) 0,10	(-) 0,15

On observe plusieurs corrélations significatives (valeur de r^2 supérieure à 0,25) entre les écarts de K et de TR et des indicateurs paysagers. Les relations sont négatives pour la surface de strate, l'écart-type

de l'altitude, et le nombre de classes, elles sont positives pour l'écart-type de l'aire des patches. La relation avec la pente moyenne n'est significative (et négative) que pour les différences de K.

3.3.1 Influence de la surface de strate

On observe une corrélation significative négative pour les écarts de K et de TR (tableau 17). La représentation graphique de la surface de strate en fonction des écarts de K et de TR (figure 27) ainsi que l'étude de la surface de végétation à classer (figure 28) propre à chaque strate permet de les répartir en 3 groupes distincts :

- Un groupe de 4 strates (groupe A), de surface élevée, supérieure à 450 000 ha, qui présentent peu d'amélioration de la qualité de la classification (écart de K inférieur à 0,1), ainsi qu'une faible hausse du rejet (4 à 5% d'écart), il s'agit des strates n°21, 23, 24 et 25 (tableau 17). Comme on peut le voir sur la figure 28, les strates du groupe A se caractérisent par une surface de végétation à classer supérieure à 120 000 ha.
- Un groupe de 3 strates (groupe C) de superficie très faible (inférieure à 100 000 ha) qui présentent un écart de K très élevé et une valeur de K sans stratification très faible (entre 0.06 et 0.36) ; il s'agit des strates n°10, 15 et 16. Le gain de K ne peut être traduit par une amélioration de la qualité de la classification car il s'accompagne d'un très fort taux de rejet, variant de 20 à 40%. D'autres strates ont une surface inférieure à 100 000 ha (strates n° 6, 7, 11, 13 et 17), toutefois leur taux de rejet ne dépasse pas 22% et leur valeur de K sans stratification est de l'ordre de 0.5. Les strates du groupe C se caractérisent par une surface de végétation à classer inférieure à 5000 ha (figure 28), ce qui peut être considéré comme un seuil critique.
- Un groupe B correspondant à la majorité des strates (18), de surface très variable mais inférieures à 450 000 ha et pour lesquels les écarts de K et de TR sont également très variables. Dans ces situations majoritaires, la relation entre écart de K et surface de strate n'est pas significative (figure 27). La surface de végétation à classer est comprise entre 5248 ha et 88 504 ha (figure 28).

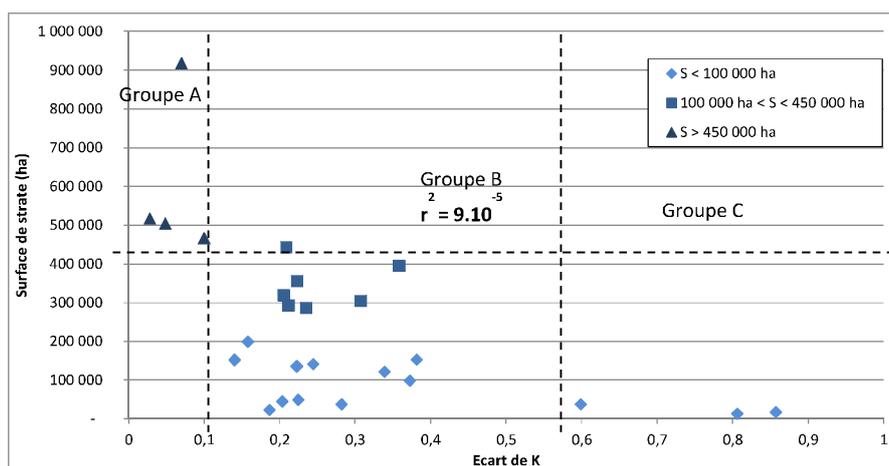


Figure 27: Relation entre la surface de strate (ha) et l'écart de K pour la période 2007-2009.

Bien que la relation entre surface des strates et gain de Kappa soit linéaire et positive si l'on considère la totalité des strates, l'interprétation ne se base pas que sur cette significativité et se fait en tenant compte d'une caractérisation des strates selon les trois groupes A, B et C. Ceci nous amène à la

conclusion que si l'on ne tient pas compte des deux situations extrêmes (groupes A et C) l'amélioration de la classification n'est pas liée à la taille des strates.

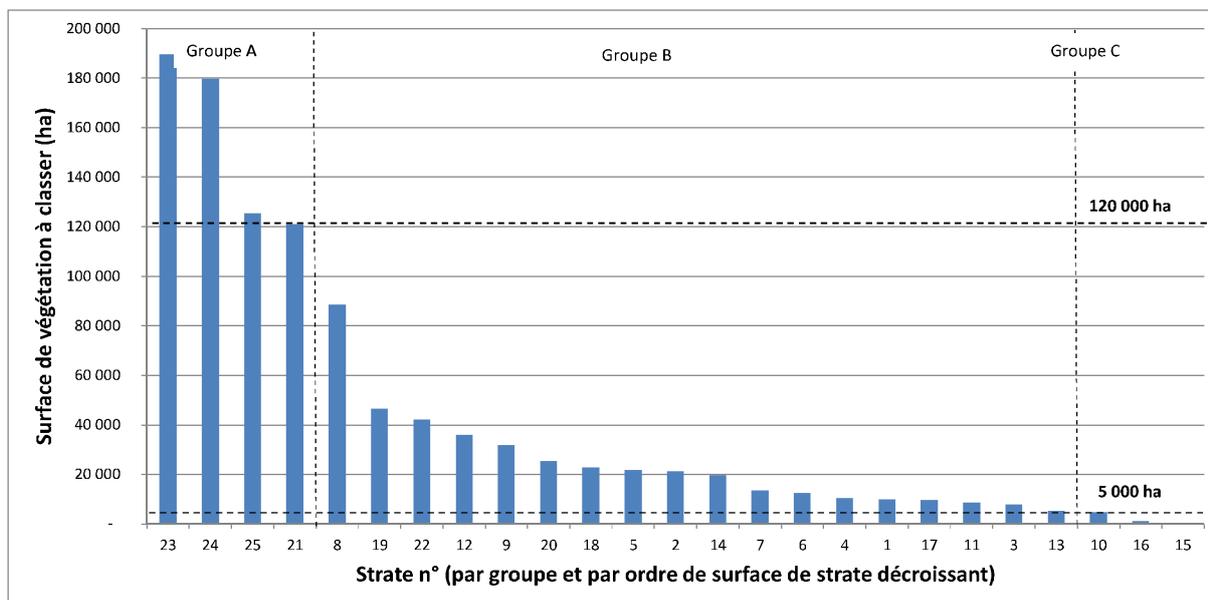


Figure 28: Surface de végétation à classer pour les 25 strates, classes par groupe et par surface décroissante.

3.3.2 Influence de la variabilité de l'altitude

Pour l'ensemble des 25 strates les corrélations entre l'écart-type de l'altitude et les écarts de K et de TR sont significatives avec des valeurs de r^2 respectivement de 0,379 et de 0,307 (tableau 17). Toutefois, pour le seul groupe B, la relation n'est pas significative, avec une valeur de r^2 de 0,156 pour l'écart de K et de 0,089 pour l'écart de TR. On peut en déduire que le facteur altitude, et plus précisément le caractère montagneux et accidenté des strates, si l'on prend également en compte l'absence de relation avec les pentes, n'est pas un facteur influençant l'efficacité de la stratification. De ce fait, aucun effet seuil ne peut être identifié. Pour les strates du groupe A, on peut supposer un effet indirect de la surface sur les résultats car ce sont les strates de plus grande surface qui présentent les écarts type d'altitude les plus élevés. Le groupe C conserve son caractère atypique, il s'agit de strates situées dans le piémont à des zones moins accidentées.

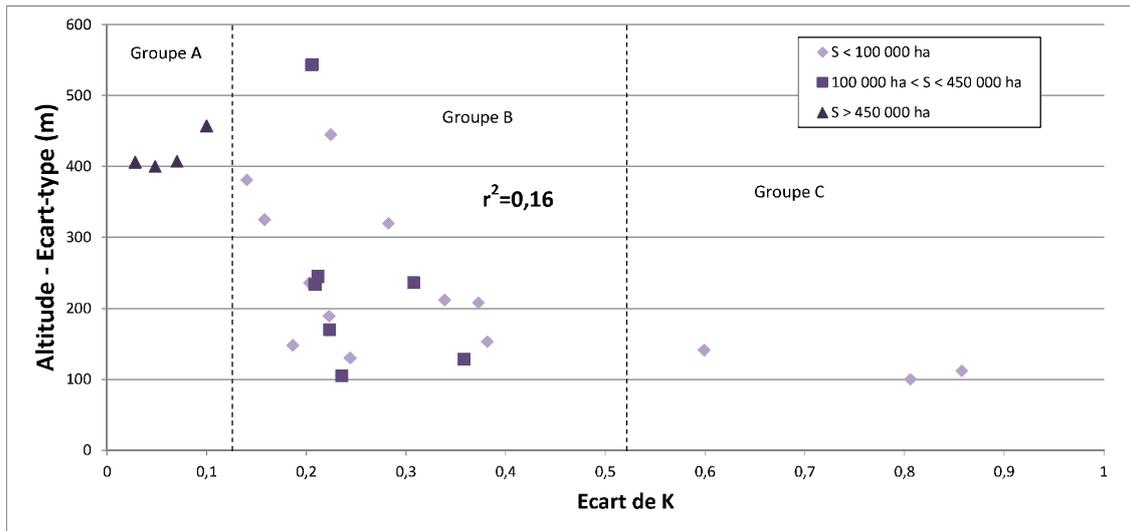


Figure 29 : Relation entre l'écart-type de l'altitude (m) et l'écart de K pour la période 2007-2009, en considérant les groupes de strates A; B et C.

3.3.3 Influence de l'écart type de l'aire des patches

La corrélation est significative et positive pour l'ensemble des 25 strates entre l'écart type de l'aire des patches et les écarts de K et de TR, avec des valeurs respectives de r^2 de 0,639 et de 0,588. L'écart-type de l'aire des patches est l'indicateur présentant les valeurs de r^2 les plus élevées (figure 30). Par contre, si on observe le groupe B, la corrélation n'est plus significative pour l'écart de K, ce qui ne nous permet pas de montrer une influence directe entre l'écart type de l'aire des patches et la qualité de classification. La corrélation reste significative pour l'écart de rejet. L'écart-type de l'aire des patches pouvant être considéré comme un indicateur de fragmentation, on peut émettre l'hypothèse que plus sa valeur est élevée, plus la fragmentation est accentuée, ce qui augmente le taux de rejet par démultiplication des effets de bordure. Les strates des groupes A et B sont toujours individualisées, ce qui témoigne de l'influence indirecte de la surface.

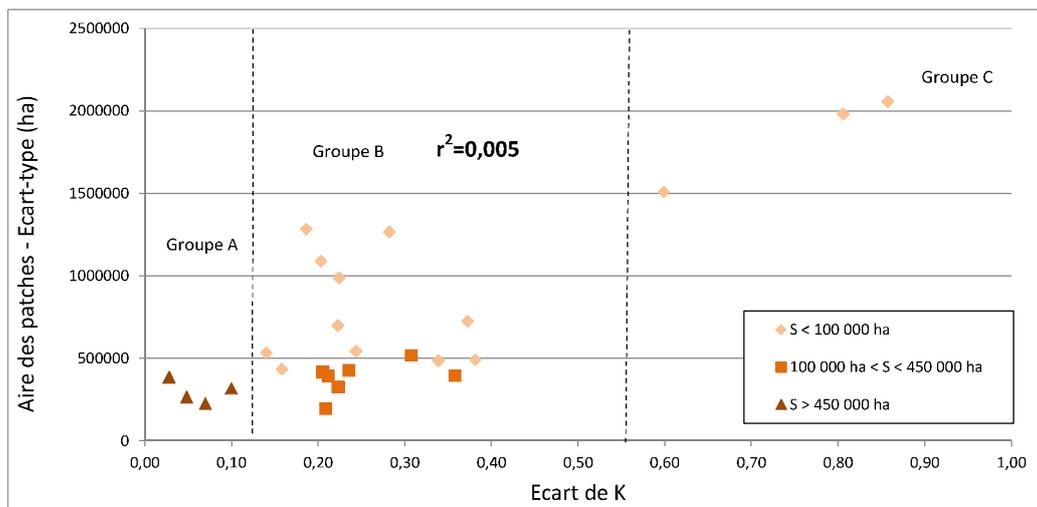


Figure 30: Relation entre l'écart-type de l'aire des patches (ha) et l'écart de K pour la période 2007-2009, en considérant les groupes de strates A, B et C.

3.3.4 Influence du nombre de classes

Comme dans les cas précédents, pour l'ensemble des 25 strates la relation entre le nombre de classes et les écarts de K et de TR est significative et négative, avec des valeurs respectives de r^2 de 0,34 et de 0,42 (tableau 17). Néanmoins, lorsqu'on considère le seul groupe B, les faibles valeurs de r^2 (0,008 pour l'écart de K et de 0,13 pour l'écart de TR) indiquent l'absence de relation significative avec ce descripteur (figure 31). L'indice de Shannon, qui caractérise également la composition du couvert forestier des strates, n'est pas significativement corrélé aux écarts de K et de TR. Ceci est sans doute à mettre en parallèle avec la prise en compte de la surface de la strate dans le calcul de l'indice.

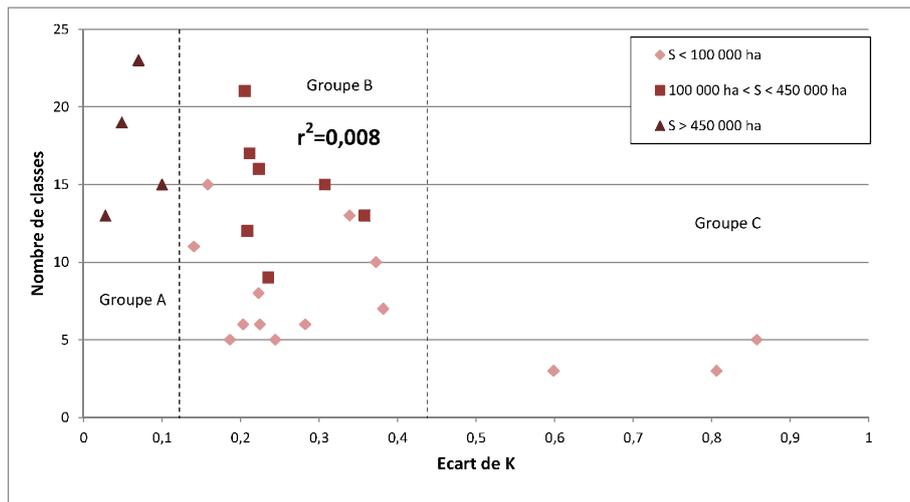


Figure 31: Relation entre le nombre de classes et l'écart de K pour la période 2007-2009 en considérant les groupes A, B et C.

Aucun des autres indices (taux de couverture forestière, pente moyenne, aire moyenne des patches, indice de morcellement) ne présente de corrélation significative avec les écarts de K et de TR (tableau 17). La topographie, la composition et la fragmentation des formations boisées ne semblent donc pas avoir d'influence sur l'efficacité de la stratification.

4 Discussion-conclusion

Les résultats de cette étude ont montré que le recours à une stratification réalisée à partir d'une série temporelle d'images satellites à moyenne résolution spatiale et selon un procédé de segmentation objet améliore de manière significative la classification supervisée appliquée à notre site d'étude. Cette amélioration est stable quelle que soit la période d'étude (2007-2009 et 2009-2011) avec, dans les deux cas, une valeur de K calculée au niveau global qui augmente de 0.12. Toutefois on note que cette amélioration s'accompagne d'une augmentation du taux de rejet des pixels à classer, de 6 et 7%, au niveau global et pour les deux périodes.

Ces augmentations globales de K et de TR se vérifient aussi quand on analyse les résultats strate par strate. On note aussi que la dispersion des valeurs de K est moindre quand la stratification est utilisée.

Au total, 22 classes de végétation ont été distinguées, avec un niveau de précision variable car allant de 13% à 93% sans stratification. L'usage de la stratification améliore la précision producteur pour toutes les classes, elle varie au final entre 40% à 80%. L'amélioration est plus importante pour les classes les moins bien classées initialement.

On a identifié les caractéristiques des strates qui ont une influence sur la qualité de la classification et la plus importante est la surface. On a pu montrer deux éléments essentiels. Premièrement, la relation entre la surface des strates et la qualité de classification est significative. Mais il ne suffit pas de l'interpréter comme une relation linéaire. Deuxièmement, des seuils critiques minimal et maximal ont été identifiés pour la surface des strates et par conséquent la surface de végétation à classer :

- au-delà de 450 000 ha et lorsque la surface de végétation à classer est supérieure à 120 000 ha les améliorations de kappa sont très faibles ;
- en dessous de 100 000 ha et lorsque la surface de végétation à classer est très réduite (< 5000 ha) les résultats sont fortement dégradés du fait de l'important taux de rejet.

Ces deux seuils limites seront à intégrer comme recommandation dans la procédure de segmentation. Ainsi lorsque l'on crée la segmentation selon la méthode de (Bisquert et al, 2015), la surface des HLU est liée à la valeur du paramètre d'échelle, sa définition est donc particulièrement importante. En appliquant la valeur 15, avant l'étape de fusion, on a obtenu 56 HLU dont 30 de surface inférieure à 100 000 ha et 1 de surface supérieure à 450 000 ha (tableau 18). Avec un paramètre d'échelle de 20, on a obtenu 39 HLU dont 15 de surface inférieure à 100 000 ha et 2 de surface supérieure à 450 000 ha. Le nombre de strates critiques est de 39 dans le premier cas et 31 dans le second. On peut confirmer que le paramètre fixé à 15 ou 20 est optimal car pour des valeurs inférieures à 15 ou supérieures à 20 on augmenterait le nombre de situations critiques soit pour les petites surface, soit pour les grandes.

Tableau 18: Comparaison des résultats de segmentation (dans le cas de l'indice de texture « moment secondaire ») pour les valeurs 15 et 20 du paramètre d'échelle et incidence sur le nombre de « strates critiques ».

Paramètre d'échelle	15	20
Nombre de HLU: total	56	39
Nombre de HLU: S < 100 000 ha	30	15
Nombre de HLU: 100 000 < S < 450 000 ha	25	22
Nombre de HLU: S > 450 000 ha	1	2
Nombre de « strates critiques »	39	31

Le paramétrage d'échelle fixé à 15, ainsi que l'indice de texture (moment secondaire) sélectionnés par la mise en œuvre de la méthode, sont identiques à ceux obtenus et appliqués à l'échelle du territoire français (Bisquert et al., 2015). Cela confirme la robustesse et la reproductibilité de cette méthode de stratification lorsque l'on travaille sur de vastes étendues. Des travaux similaires menés sur le Mali (Vintrou et al., 2012) ont conduit à des choix différents en termes d'indice de texture. Ces différences peuvent être liées, (i) à l'indice de végétation utilisé pour la segmentation objet (NDVI et non EVI), (ii) au type de paysage.

Cette méthode, développée à l'origine pour la cartographie du paysage, peut donc être préconisée pour améliorer la cartographie, par classification supervisée, de grandes surfaces présentant de fortes variabilités topographiques et du couvert végétal. Dans le cadre de son application pour la classification, une étape de fusion des plus petites strates sera forcément nécessaire. Elle peut être facilement réalisée avec l'approche statistique proposée dans cette étude (prenant en compte la similarité des occupations du sol). De même, un découpage des strates de surface trop importante pourrait être aisément réalisé selon des critères simples de photo-interprétation.

L'approche de stratification basée sur une analyse de paysage proposée ici est du même niveau d'efficacité que les approches habituellement rencontrées dans la littérature (Haralick et al., 1973) et qui sont basées soit sur l'utilisation de cartes thématiques existantes soit sur un savoir expert. Or, on n'a utilisé ici que des données de télédétection facilement accessibles et la méthode proposée s'affranchit de toute expertise.

L'analyse des caractéristiques paysagères des strates amène des éléments opérationnels de définition des strates qui pourront être utilisés pour ajuster les paramètres lors de la construction des HLU et la définition des strates. Il s'agit principalement de seuils de surface (surface totale et surface de végétation à classer).

L'analyse des indicateurs de qualité montre que le seul indice de Kappa n'est pas suffisant pour apprécier le résultat, il doit être pondéré par une analyse du rejet.

Les résultats obtenus nous permettent de conclure que le recours à une segmentation objet comme outil de stratification permet d'améliorer encore ces résultats de classification, dans le cas d'une approche probabiliste, appliquée par pixel. Malgré l'emploi d'une nomenclature forestière détaillée (une vingtaine de classes), la qualité obtenue est satisfaisante. Cet outil de stratification a ainsi permis d'obtenir un gain de précision globale ainsi qu'une précision producteur plus élevée pour chaque classe.

L'étude n'a pas permis d'identifier une influence particulière des caractéristiques topographiques et paysagères sur l'action de cette stratification basée sur des unités homogènes sur le plan radiométrique. Elle a toutefois permis de mettre en évidence un effet seuil maximal de la surface de strate sur cette action, au-delà de laquelle aucun apport n'est observé (environ 450 000 ha pour notre étude). En-dessous d'une certaine valeur minimale (100 000 ha pour notre étude), des conditions critiques pour la classification sont susceptibles de survenir, correspondant à un jeu d'entraînement sous-dimensionné. Ce constat nous permet de conclure que la mise en œuvre d'une telle stratification doit reposer sur une vérification préalable du dimensionnement de la segmentation objet relative à ces cas extrêmes.

Ces premiers résultats indiquent toutefois que la méthodologie de segmentation objet appliquée pourrait constituer une alternative objective et reproductible aux stratifications reposant sur un savoir expert.

La question de la reproductibilité de cette méthodologie à une résolution spatiale plus fine se pose avec la perspective de l'arrivée des futures données satellitaires Sentinel-2. Elles permettront de concilier haute répétitivité temporelle et haute résolution spatiale, ce qui constitue un apport certain à la classification de la végétation de territoires de grande étendue.

La notion de texture paysagère de la végétation ainsi que la définition spatiale des formations végétales et de leurs signatures à partir d'indices de végétation seront abordées à une autre échelle. Il en sera de même pour la segmentation objet. Dans ce contexte, une perspective d'approfondissement de cette étude consisterait à étudier l'action de la stratification sur une telle série temporelle.

Pour cette étude, l'algorithme de classification retenu était l'approche probabiliste du maximum de vraisemblance. La végétation forestière de notre site d'étude présente une distribution spatiale complexe. On a constaté que cette configuration est susceptible d'induire une variabilité spatiale importante de la signature représentative d'une unique formation végétale, ainsi que des confusions notables entre les signatures de formations végétales ayant des essences en commun. L'étude du recours à une stratification pour la classification par maximum de vraisemblance a montré que cette méthode permettait de réduire cette variabilité (augmentation de l'indice de Kappa) mais s'accompagnait également d'une perte de représentativité (augmentation du rejet). Dans ce contexte, au-delà d'une optimisation par stratification, une incertitude existe sur l'adéquation de nos données au maximum de vraisemblance. Cette inadéquation peut être liée à une configuration non optimale du maximum de vraisemblance, du fait :

- d'un jeu d'entraînement de dimensionnement et d'homogénéité inadaptés,
- d'une forme inadaptée de la série temporelle traitée.

Au-delà de la notion de configuration optimale, il est également possible que la distribution et la séparabilité des signatures ne correspondent pas aux prérequis statistiques de la règle de décision du maximum de vraisemblance. Cette éventualité doit être envisagée et est étudiée dans le chapitre suivant qui a pour objet de comparer les résultats obtenus par le maximum de vraisemblance à ceux produits par deux autres algorithmes de classification.

Cette étude a fait l'objet d'une publication, actuellement sous révisions mineures :

Cano, E., Denux, J.P., Bisquert, M., Hubert-Moy, L., et Chéret, V. (accepté), Improved forest cover mapping based on MODIS time series and landscape stratification, International Journal of Remote Sensing, *sous révisions mineures*.

Chapitre IV : Amélioration et comparaison de trois procédures de classification

1 Introduction

Ce chapitre porte sur les particularités des classifications réalisées à partir de séries temporelles. Dans le chapitre précédent, le travail n'a porté que sur l'entraînement et l'impact de la stratification sur les résultats de la classification. Ce chapitre est focalisé sur l'analyse de l'influence de l'organisation des séries temporelles d'images traitées sur la précision des classifications.

Deux échelles temporelles ont été prises en compte : la première, interannuelle, considère la caractérisation du cycle phénologique annuel ; la deuxième, annuelle, permet de prendre en considération la variabilité de ce cycle sur plusieurs années consécutives. La composition de l'entraînement, le choix des données images d'entrée et de l'algorithme utilisé sont analysés à ces deux échelles.

Les procédures de classification mises en œuvre sont basées sur trois algorithmes : Maximum de Vraisemblance ou ML (Dymond et al., 2002), Support Vector Machine ou SVM (Cortes et Vapnik, 1995), Random Forest ou RF (Breiman, 2001). Nous avons conservé ML pour sa robustesse et sa large utilisation dans la cartographie. Nous avons émis l'hypothèse que les deux autres algorithmes, non paramétriques et plus innovants, pourraient améliorer les résultats à condition de maîtriser leur mise en œuvre.

Dans ce chapitre, nous avons repris le site d'étude et les données MODIS utilisées dans le chapitre précédent.

La démarche appliquée est structurée en deux parties.

La première porte sur l'évaluation comparative de la performance des trois algorithmes de classification. Pour cela, ont été analysés, par étapes successives, l'effet du taux d'échantillonnage utilisé pour l'entraînement, de la mixité des pixels d'entraînement, de la composition temporelle des données images, de la composition radiométrique des données images et de l'ajout de données ancillaires (figure 32). A chaque étape, seul le meilleur résultat de classification a été conservé pour l'étape suivante. Le critère de qualité retenu pour choisir la meilleure configuration est l'indice de Kappa.

La deuxième étape correspond à l'analyse des résultats issus de la meilleure configuration retenue pour chaque algorithme. Pour cela, l'analyse porte sur les dimensions temporelle, spatiale et thématique. Ces résultats permettent de mettre en évidence les intérêts et les limites des classifications des séries temporelles à moyenne résolution spatiale dans le contexte de l'étude.

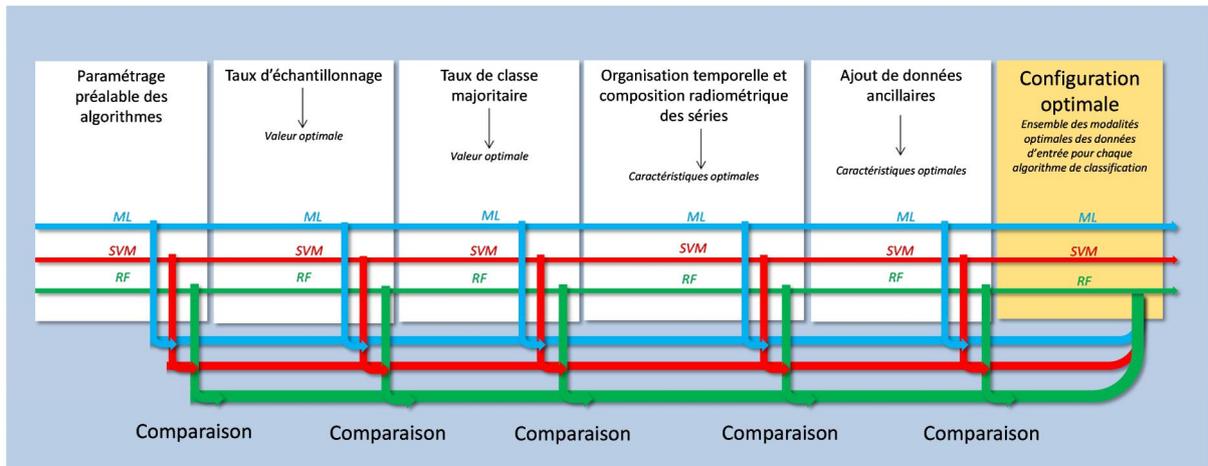


Figure 32 : Démarche générale de la première partie de la procédure de comparaison des trois algorithmes de classification.

2 Méthodes

2.1 Organisation des procédures de classification

2.1.1 Paramétrage des algorithmes de classification

Il convient d'ajuster un certain nombre de paramètres nécessaires au fonctionnement des algorithmes SVM, RF et ML.

Cet ajustement s'est basé tant que possible sur les exemples et méthodes proposés dans la littérature. En l'absence de telles indications, la mise en œuvre de tests préalables s'est avérée nécessaire pour définir le paramétrage adapté.

2.1.1.1 Maximum de vraisemblance (ML)

Pour cette étude, le paramétrage de l'algorithme ML sous ArcGis 10 a consisté à fixer :

- les probabilités d'appartenance *a priori* de chaque classe, qui ont été supposées égales,
- le seuil de rejet à 0 pour pouvoir comparer les résultats avec ceux obtenus avec les deux autres méthodes utilisées dans l'étude (SVM et RF) pour lesquelles on ne peut pas estimer de rejet.

2.1.1.2 Support Vector Machine (SVM)

La méthode de classification SVM a été mise en œuvre à partir du logiciel de traitement d'images Orfeo Tool Box (OTB), développée par le CNES (version 4.2.0).

Le paramétrage de l'algorithme de la méthode SVM nécessite de fixer en premier lieu le choix de la fonction de définition de l'hyperplan. Il existe 4 types de fonctions couramment employées, correspondant à différentes formes de l'hyperplan :

- linéaire (« Linear »),
- de base radiale (« Gaussian radial basis function »),
- polynomial (« Polynomial »),
- sigmoïde (« Sigmoid »).

Pour notre étude, le choix s'est porté sur la fonction de base radiale, recommandée pour son efficacité sans avoir de connaissance *a priori* des caractéristiques des échantillons et pour sa simplicité de paramétrage (Chang et Lin, 2013 ; Hsu et al., 2010).

Il est également nécessaire de fixer la valeur du paramètre C, nommé paramètre de pénalité (« penalty parameter »), exprimant le compromis à faire entre la minimalisation de l'erreur d'apprentissage et la maximisation de la marge (Cortes et Vapnik, 1995). Le choix de la fonction de base radiale implique par ailleurs de fixer la valeur du paramètre γ , qui définit le voisinage des points, c'est-à-dire la zone d'influence individuelle de chaque échantillon. L'efficacité du modèle de classification repose sur l'optimisation des valeurs de C et γ . En l'absence de connaissance *a priori* de ces valeurs, comme c'est le cas pour notre étude, il est possible d'optimiser automatiquement ces paramètres à partir du jeu d'entraînement pour chaque classification réalisée.

2.1.1.3 *Random Forest (RF)*

Présentation des paramètres

La méthode de classification Random Forest a été mise en œuvre à partir de l'application OTB. L'algorithme RF nécessite de définir les paramètres caractéristiques de la forêt d'arbres de décision :

- la profondeur de l'arbre,
- le nombre minimum d'échantillons utilisé à chaque nœud de l'arbre,
- le critère de terminaison des arbres,
- la valeur seuil de regroupement pour obtenir un premier niveau de séparation optimale,
- le nombre de variables choisies aléatoirement pour la sous division à chaque nœud de l'arbre,
- le nombre maximum d'arbres,
- la précision suffisante (basée sur l'erreur « Out of Bag »).

Certains paramètres ont une grande influence sur la précision des résultats de classification. Ces paramètres, indiqués en bleu dans le tableau 19, sont la profondeur de l'arbre, le nombre de variables choisies à chaque nœud et le nombre maximum d'arbres. Des tests ont été réalisés pour ajuster leurs valeurs à la configuration des classifications réalisées. Ils ont consisté à réaliser des classifications de test pour plusieurs valeurs du paramètre à optimiser et à comparer les précisions obtenues à partir du jeu de validation. La précision des classifications a été évaluée à partir de l'indice de Kappa. Pour les autres paramètres, qui ont peu d'influence sur les résultats, les valeurs par défaut ont été conservées.

Réglage de la profondeur de l'arbre

La profondeur de l'arbre correspond au nombre « d'étapes » suivies par les séparations. Plus cette valeur est grande, plus le modèle de séparation des classes est précis. Un compromis doit être trouvé entre une valeur trop faible, donnant un modèle de classification peu adapté aux données traitées et une valeur trop importante, risquant d'aboutir à un phénomène « d'overfitting ». Ce phénomène se traduit par l'obtention d'un modèle de classification trop adapté au jeu d'entraînement et qui se généralise mal à la totalité des pixels à classer. La valeur par défaut du paramètre dans OTB est 5.

De premiers tests réalisés sur le paramétrage de la profondeur de l'arbre ont rapidement mis en évidence que sa valeur par défaut n'était pas adaptée et certainement trop faible. En effet, les classifications obtenues avec cet ajustement ne présentaient jamais l'intégralité des 24 classes de la nomenclature : 6 à 9 classes étaient systématiquement absentes. L'ajustement a donc été testé sur une gamme de valeurs supérieures à 5, variant entre 10 et 35. Les résultats obtenus (figure 33) montrent que l'ajustement de ce paramètre permet une légère amélioration de l'indice de Kappa. On observe une stabilisation de la précision à partir de la valeur 25. Cette valeur, pour laquelle aucune classe n'est exclue des résultats, correspond au nombre de classes de la nomenclature. Pour l'ensemble des classifications à mettre en œuvre avec la méthode Random Forest, la valeur du paramètre a donc été fixée égale au nombre de classes de la nomenclature, c'est-à-dire 24.

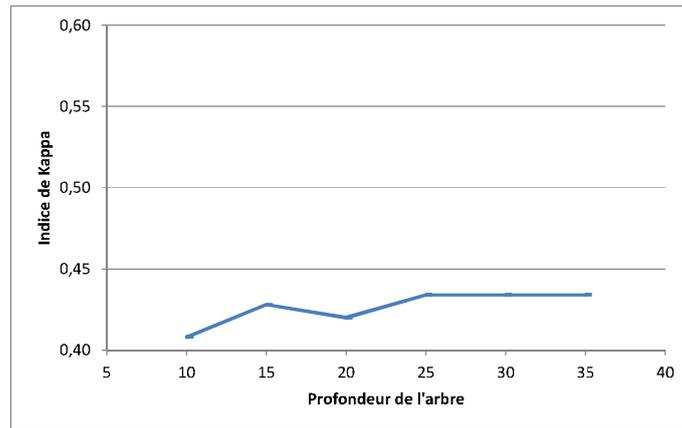


Figure 33 : Valeur de l'indice de Kappa en fonction de la profondeur de l'arbre. Pour ces tests, on a conservé la valeur par défaut des autres paramètres, notamment du nombre d'arbres (fixé à 100) et du nombre de variables (fixé à 0).

Réglage du nombre de variables

Le nombre de variables prises en compte pour le tirage aléatoire à chaque nœud correspond ici au nombre total d'images prises en compte pour la construction de l'échantillon. Par défaut, le nombre de variables est fixé à 0. Dans la littérature, il est conseillé d'utiliser la racine carrée du nombre d'images à classer (Corcoran et al., 2013 ; Gislason et al., 2006 ; Senf et al., 2012).

Une fois la caractéristique optimale identifiée pour la profondeur de l'arbre, le paramètre correspondant au nombre de variables pour le tirage aléatoire a été testé à partir de la même série temporelle. La série se compose de 69 images, soit 69 variables prédictives, la valeur conseillée étant approximativement fixée à 8. Le test a consisté à faire varier le nombre de variables entre 0, la valeur par défaut, et 69 (figure 34). On observe une forte évolution du Kappa qui passe de 0,43 à 0,56, quand le nombre de variables passe de 0 à 32. On peut déduire de cette évolution que, pour un nombre de variables inférieur à 32, chaque information donnée par une variable supplémentaire rend le modèle plus efficace pour séparer précisément les classes. Au-delà, les informations complémentaires apportées sont moins utiles au modèle.

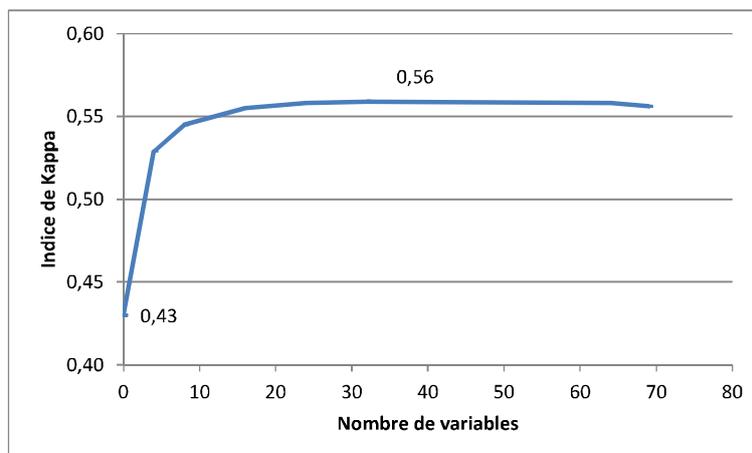


Figure 34 : Indice de Kappa en fonction du nombre de variables pour le tirage aléatoire. Pour ces tests, on a conservé la valeur par défaut des autres paramètres, notamment le nombre d'arbres (fixé à 100) et la valeur optimale de la profondeur de l'arbre (fixée à 24).

La valeur 8, conseillée dans la littérature, donne un résultat acceptable. Cependant, nous avons retenu le nombre de 32, qui donne le meilleur résultat pour la mise en œuvre des classifications supervisées avec la méthode Random Forest.

Réglage du nombre d'arbres

Théoriquement, plus le nombre d'arbres est élevé, meilleure est la précision de la classification. Un effet de saturation existe toutefois au-delà d'un certain seuil, qu'il convient de déterminer. Le temps de calcul propre à la classification augmente également de façon linéaire avec le nombre d'arbres. La valeur du paramètre est fixée par défaut à 100.

La gamme de valeur proposée par OTB est large et il est possible de traiter plusieurs milliers d'arbres. On sait toutefois que ce paramètre sollicite la mémoire de l'ordinateur et peut rencontrer des limites liées à la capacité de cette mémoire. La gamme de valeurs testée varie entre 100 et 10 000. Avec le matériel disponible, la saturation liée à la sollicitation de la mémoire a été rencontrée au-delà de 2000 arbres (figure 35). Les résultats obtenus ne montrent pas de réelle augmentation de la précision entre 100 et 2000 arbres. Le nombre d'arbres a été fixé à 500 pour l'ensemble des classifications supervisées mises en œuvre avec la méthode Random Forest. Ce résultat confirme d'autres paramétrages trouvés dans la littérature (Corcoran et al., 2013 ; Grinand et al., 2013).

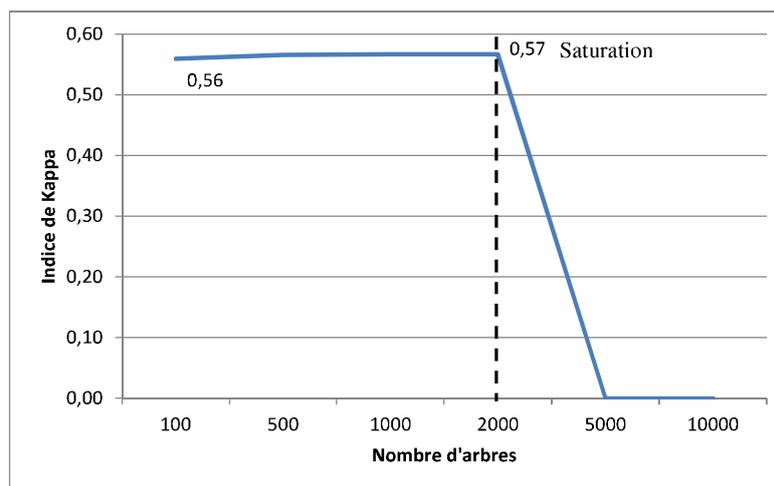


Figure 35 : Indice de Kappa en fonction du nombre d'arbres. Pour ces tests, on a conservé la valeur optimale du nombre d'arbres (fixé à 500) et de la profondeur de l'arbre (fixée à 24) ainsi que la valeur par défaut des autres paramètres.

Valeurs des autres paramètres

Le nombre minimal d'échantillons à utiliser à chaque nœud de l'arbre correspond dans notre cas à l'effectif de pixels à classer auxquels la règle de décision correspondant au nœud est appliquée. La valeur théorique recommandée correspond à la valeur minimale de 1% des pixels du jeu d'entraînement. Sa valeur est fixée par défaut à 10.

En théorie, les arbres aléatoires de la méthode Random Forest ne peuvent être générés à l'infini et doivent répondre à une règle d'arrêt, ou critère de terminaison. Une règle couramment utilisée consiste à ne pas découper les nœuds qui contiennent moins d'un certain nombre d'échantillons. Dans le cas de l'algorithme proposé par OTB, le critère de terminaison repose sur le calcul de l'écart entre la valeur d'un pixel pris au hasard dans l'échantillon d'un nœud et chacune des autres valeurs présentes dans cet

échantillon. La terminaison a lieu lorsque tous les écarts ainsi calculés dans l'échantillon du nœud sont inférieurs à la valeur saisie par l'utilisateur. La valeur par défaut du paramètre est 0.

Afin de diminuer le temps de calcul et la quantité de données à traiter simultanément, l'algorithme réalise, à chaque nœud, une recherche préalable de séparation optimale pour un sous-ensemble de l'échantillon. La séparation optimale n'est pas recherchée pour les 24 classes à la fois mais pour des regroupements de classes, ne dépassant pas un nombre maximal. Le nombre de classes du sous-ensemble est ainsi limité par un seuil, nommé valeur seuil de regroupement, à laquelle il est inférieur ou égal. La valeur par défaut de ce paramètre est fixée à 10.

Le dernier paramètre à ajuster est celui de la précision suffisante. L'algorithme calcule la proportion d'observations mal classées par la classification (erreur « Out-Of-Bag »). Elle ne doit pas dépasser la valeur saisie par l'utilisateur. Sa valeur par défaut est fixée à 0,01.

On peut remarquer que l'algorithme RF est robuste et peu sensible à un réglage fin de la plupart des paramètres. Seuls les paramètres nombre de variable à chaque nœud et, dans une moindre mesure, la profondeur de l'arbre, ont un impact sur la qualité des classifications. Le paramétrage final appliqué pour l'ensemble de l'étude est présenté dans le tableau 19.

Tableau 19 : Paramètres propres à la méthode de classification Random Forest. En bleu : paramètres dont l'ajustement requiert des tests préalables.

Description	Valeur par défaut	Valeur fixée pour l'étude
Profondeur de l'arbre	5	24
Nombre minimum d'échantillons utilisé à chaque nœud de l'arbre	10	10
Critère de terminaison des arbres	0	0
Valeur seuil de regroupement pour obtenir un premier niveau de séparation optimale	10	10
Nombre de variables choisies aléatoirement pour la sous division à chaque nœud de l'arbre	0	32
Nombre maximum d'arbres	100	500
Précision suffisante (basée sur l'erreur « Out of Bag »)	0,01	0,01

2.1.2 Jeu d'entraînement

2.1.2.1 Variation du taux d'échantillonnage

Le taux d'échantillonnage est le rapport entre l'effectif total du jeu d'entraînement et l'effectif de pixels à classer. Pour cette étude, on définira cette population de pixels comme la totalité des pixels des images MODIS prétraitées (2857 colonnes et 1514 lignes) dont on déduit :

- les pixels qui sont contenus à moins de 80% dans la carte de référence,
- les pixels auxquels on ne peut attribuer de classe de formation végétale définie (taux de classe majoritaire inférieur à 50%).

On dénombre ainsi 540 467 pixels à classer au total. On a souhaité étudier des valeurs de taux d'échantillonnage encadrant la valeur précédemment testée (chapitre III), proche de 6%. Nous avons fait varier le taux d'échantillonnage depuis un minimum très faible de 0,1% jusqu'à un maximum possible de 17,8%.

SVM impose d'utiliser un jeu d'entraînement où chaque classe est caractérisée par le même nombre de pixels (Foody et Mathur, 2004). Par souci de comparaison, nous avons appliqué cette règle aux 3 algorithmes. Les effectifs fixés par classe pour chaque taux d'échantillonnage sont présentés dans le tableau 20.

La classe la moins représentée limite l'effectif possible de pixels et fixe donc le taux d'échantillonnage maximal. Ici on atteint une valeur de maximale de 17,8%.

Tableau 20 : Définition des taux d'échantillonnage.

Taux d'échantillonnage	Effectif total du jeu d'entraînement (pixels)	Effectif par classe (pixels)
0,1%	528	22
0,25%	1368	57
0,5%	2688	112
1%	5689	225
3%	16345	861
5%	27746	1156
7%	37824	1576
10%	53229	2217
17,8%	96000	4000
Echantillonnage maximal possible		

2.1.2.2 Variation du taux de classe majoritaire

On s'attend à ce qu'un « pixel mixte », tel que défini dans le chapitre I, ait une signature moins représentative d'une classe donnée qu'un « pixel pur ». Il paraît ainsi préférable, lorsqu'on a recours à la méthode de classification du maximum de vraisemblance, d'éviter d'intégrer des pixels mixtes au jeu d'entraînement. A l'inverse, pour des méthodes reposant sur un principe de séparation des classes telles que SVM, l'information contenue dans un pixel mixte peut s'avérer utile (Foody et Mathur, 2004 ; Foody et Mathur, 2006). On a souhaité étudier l'influence de différentes compositions du jeu d'entraînement en fonction du taux de classe majoritaire des pixels (tableau 21). Nos hypothèses initiales sont :

- qu'un taux de classe majoritaire de 100% est plus adapté au ML,
- que la prise en compte des pixels avec un taux de classe majoritaire plus faible est favorable à SVM.

Concernant RF, aucune référence n'abordant cet élément technique, les observations que l'on peut faire constituent une avancée méthodologique.

Tableau 21 : Définition des seuils de taux de classe majoritaire pour la construction du jeu d'entraînement.

Seuil fixé	Taux de classe majoritaire (TCM)
50 % CM	50% <=TCM <=100%
70% CM	70% <=TCM <=100%
90% CM	90% <=TCM <=100%
100% CM	TCM =100%

2.1.3 Organisation temporelle des séries d'images

Les tests ont porté sur plusieurs séries temporelles MODIS dont on a fait varier la composition selon deux échelles temporelles (figure 36).

A l'échelle du cycle phénologique annuel, ont été prises en compte :

- la série annuelle complète composée de 23 synthèses,
- une série « hors hiver », de 17 dates, qui ne prend pas en compte les mois d'hiver (décembre, janvier et février). On élimine la période hivernale pour limiter le bruit et les erreurs liés aux nuages et à la neige qui dégradent la qualité des images et donc de la classification,
- une série de 3 dates. On veut vérifier si 3 dates sont suffisantes pour caractériser le cycle phénologique et permettent d'obtenir une classification d'aussi bonne qualité que les deux séries temporelles précédentes. On a utilisé une Analyse en Composantes Principales (Pearson, 1901) pour identifier les dates qui apportaient le plus d'information. Les 3 dates correspondent aux synthèses qui débutent les 22 mars, 12 juillet et 1^{er} novembre.

Pour prendre en compte la variabilité du cycle sur plusieurs années consécutives, trois types de séries ont été constituées sur 3 durées (1, 2 ou 3 années consécutives), sur la période 2000 à 2002. Pour ces séries et sur ces différentes durées, on prendra en compte soit l'ensemble des images soit les moyennes calculées sur 2 ou 3 ans. L'hypothèse est que ces moyennes permettent de lisser les profils et de s'affranchir de valeurs atypiques extrêmes liées à l'acquisition des images.

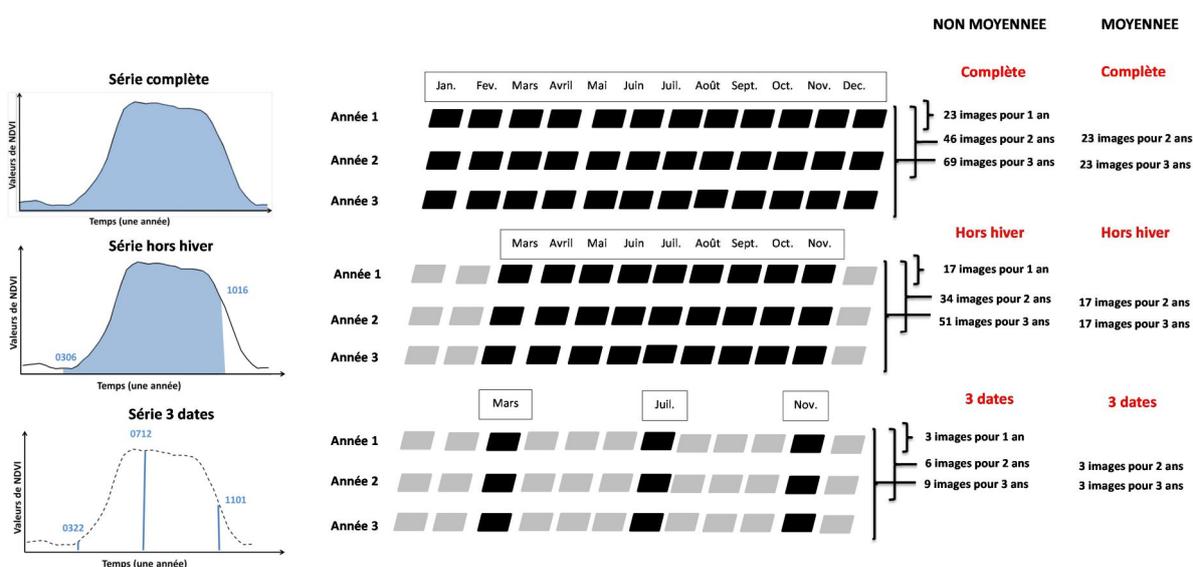


Figure 36 : Représentation schématique de la composition des séries étudiées

2.1.4 Composition radiométrique des séries

Les séries temporelles décrites précédemment ont été construites avec divers types de données radiométriques :

- deux indices de végétation, le NDVI et l'EVI. Le NDVI est l'indice de végétation le plus largement utilisé, une des limites connues étant la saturation des valeurs pour les végétations très actives. L'EVI a été proposé pour lever cette limite. Ici, on émet l'hypothèse que les séries d'EVI devraient permettre une meilleure description des cycles phénologiques et donc une différenciation plus efficace des classes.
- deux combinaisons de bandes spectrales : Rouge et Proche-Infrarouge (R+NIR) et Rouge, Proche-Infrarouge et Moyen Infrarouge (R+NIR+MIR),

La combinaison des différentes modalités possibles définit 60 séries de données de taille variables allant de 3 à 207 images par classification (tableau 22).

Tableau 22 : Nombre total d'images composant les 60 séries temporelles. Durée : 1- une année (année 2000) ; 2- deux années (2000-2001) ; 3- trois années (2000-2002).

Nature des données	Type de série et durée														
	Série non moyennée									Série moyennée					
	Série complète (23)			Série hors hiver (17)			Série sur 3 dates (3)			Série complète		Série hors hiver		Série sur 3 dates	
	DUREE														
	1 an	2 ans	3 ans	1 an	2 ans	3 ans	1 an	2 ans	3 ans	2 ans	3 ans	2 ans	3 ans	2 ans	3 ans
Réflectances: R+NIR	46	92	138	34	68	102	6	12	18	46	46	34	34	6	6
Réflectances: R+NIR+MIR	69	138	207	51	102	153	9	18	27	69	69	51	51	9	9
Indices de végétation : EVI	23	46	69	17	34	51	3	6	9	23	23	17	17	3	3
Indices de végétation : NDVI	23	46	69	17	34	51	3	6	9	23	23	17	17	3	3

2.1.5 Ajout de données ancillaires

Les données ancillaires utilisées sont l'altitude et le rayonnement solaire global. On a complété les séries, soit avec l'altitude seule, soit avec l'altitude et le rayonnement solaire global. Ces données ont été normalisées directement avec OTB.

2.2 Enchaînement des étapes de traitement

Les caractéristiques des procédures présentées précédemment sont analysées successivement : d'abord le jeu d'entraînement, puis la forme des séries temporelles et enfin les données images.

A chaque étape, des classifications sont réalisées pour les différentes modalités de la caractéristique analysée, les autres restant invariables. Les résultats pour ces différentes modalités sont comparés avec l'indice de Kappa. Seule la modalité présentant la valeur de Kappa la plus élevée est conservée à l'étape suivante. Dans ce cas, l'indice de Kappa est calculé avec les pixels de la carte forestière de référence.

La qualité du résultat final, pour chaque algorithme de classification, est validée en calculant un indice de Kappa à partir d'un jeu de données indépendantes constituées des placettes d'observation des inventaires forestiers. Il se compose de 2383 pixels au total, soit 0,44% des pixels classés. Ces pixels correspondent à 15 formations végétales de la nomenclature forestière utilisée (cf chapitre II).

Le temps de calcul nécessaire à la mise en œuvre de chaque classification a été mesuré. Il constitue un indicateur complémentaire au Kappa et est utilisé pour aider à fixer certains seuils, pour le taux d'échantillonnage par exemple.

Toutes les étapes sont mises en œuvre pour chacun de trois algorithmes (ML, SVM et RF) (figure 37).

La première étape porte sur les caractéristiques du jeu d'entraînement. On a fait varier le taux d'échantillonnage suivant 9 modalités, pour des valeurs comprises entre 0,1% et 17,8%. Le taux majoritaire est fixé à 50%. Les données images sont une série de NDVI sur une année complète et il n'y a pas de donnée ancillaire utilisée.

La deuxième étape concerne la deuxième caractéristique du jeu d'entraînement, la variation du seuil de taux de classe majoritaire, soit 4 modalités comprises entre 50% et 100%. Pour chaque algorithme, le meilleur taux d'échantillonnage de l'étape précédente est appliqué (caractéristique optimale). On utilise les mêmes données images.

La troisième étape est consacrée à la composition temporelle et radiométrique de la série, soit 60 modalités en fixant les caractéristiques du jeu d'entraînement à leur valeur optimale:

- pour le NDVI, on a comparé l'ensemble des séries (complète, hors hiver et 3 dates) sur des durées de 1, 2 et 3 ans, pour des valeurs non moyennées et moyennées, sans données ancillaires,
- cette comparaison est répétée pour le EVI, puis pour les combinaisons de bandes spectrales R+NIR et R+NIR+MIR.

La dernière étape concerne l'apport de données ancillaires. Deux modalités sont testées, l'altitude et l'altitude + le rayonnement global, toutes les autres caractéristiques étant fixées à leur valeur optimale.

	CARACTERISTIQUES				M L R F S V M
	Taux d'échantillonnage	Seuil du taux de classe majoritaire	Organisation temporelle et composition radiométrique de la série	Ajout de données ancillaires	
ETAPE 1	ETUDIEE 0,1% -> 17,8% 9 modalités	FIXEE 50% CM	FIXEE UNE ANNEE COMPLETE DE NDVI ANNEE 2000	FIXEE PAS DE DONNEES ANCILLAIRES	
ETAPE 2	OPTIMALE	ETUDIEE 50% CM -> 100% CM 4 modalités	FIXEE UNE ANNEE COMPLETE DE NDVI ANNEE 2000	FIXEE PAS DE DONNEES ANCILLAIRES	
ETAPE 3	OPTIMALE	OPTIMALE	ETUDIEE VARIATION MULTICRITERES 60 modalités	FIXEE PAS DE DONNEES ANCILLAIRES	
ETAPE 4	OPTIMALE	OPTIMALE	OPTIMALE	ETUDIEE + altitude / + altitude+ Rayonnement global 2 modalités	

Figure 37 : Récapitulatif des modalités techniques d'optimisation et de comparaison.

2.3 Interprétation des résultats de classification

Pour chaque caractéristique, les modalités optimales ont été retenues pour la suite de l'étude. L'objectif de cette partie est d'analyser la qualité des résultats obtenus en appliquant cette configuration optimale pour chaque algorithme (ML, SVM et RF) et pour l'ensemble de la série 2000-2014. Les résultats sont interprétés de manière globale et par classe, selon les dimensions temporelle, spatiale et thématique.

2.3.1 Analyse temporelle et spatiale des résultats

Des classifications ont été réalisées sur une durée de 3 ans (nommées « séries 3ans ») répétée sur la période 2000-2014, soit 13 classifications.

Dans un premier temps, on a cherché à analyser la **variabilité temporelle de la qualité des classifications**. Pour cela, on a observé l'évolution de la qualité des classifications sur la période 2000-2014. Les indicateurs utilisés sont les coefficients de Kappa calculés d'une part, à partir de l'ensemble des pixels, d'autre part, à partir des placettes de contrôle IFN.

Pour chacune des classes, l'indicateur F-Score a également été calculé pour les 13 classifications et pour les deux jeux de validation.

Dans un deuxième temps, on a cherché à analyser la **variabilité des proportions de pixels bien classés**. L'utilisation de la carte forestière de référence permet de cartographier l'ensemble des pixels

bien ou mal classés pour chaque « série 3 ans ». Un exemple cartographique de cet indicateur est donné pour la série 2000-2002, pour chaque algorithme. On peut ainsi visualiser la répartition spatiale des erreurs de classification.

Le deuxième indicateur utilisé est la « **fréquence** ». Elle représente, pour un pixel donné, le nombre de fois où la classe attribuée par la classification correspond à celle de la donnée de référence (pixel bien classé) sur la totalité des 13 « séries 3 ans ». Sa valeur varie entre 0 (pixel toujours mal classé) et 13 (pixel toujours bien classé).

Le troisième indicateur calculé est la « **variabilité** ». La variabilité représente, pour un pixel donné, le nombre de classes différentes attribuées par la classification sur la totalité des 13 « séries 3 ans ». Sa valeur varie entre 1 (pixel toujours affecté à la même classe) et 13 (pixel toujours affecté à une classe différente).

Ces deux derniers indicateurs apportent une information complémentaire à la série de Kappa calculée sur toutes les classifications. Ils peuvent être cartographiés et leur combinaison renseigne sur la stabilité de l'affectation des classes. L'analyse est ainsi complétée par une observation de la répartition spatiale de ces valeurs de stabilité.

Le dernier point est la caractérisation de l'influence du morcellement ou de l'hétérogénéité du couvert forestier sur la répartition des pixels bien classés. On a mis en relation, pour chaque pixel, la surface du polygone auquel il appartient avec sa valeur de fréquence. L'hypothèse est que les pixels les plus fréquemment mal classés appartiennent à des polygones de petite surface.

2.3.2 *Analyse thématique des résultats*

Dans cette partie la qualité de classification est évaluée thématiquement avec une analyse par classe. L'objectif est de montrer les variations de cette qualité entre les classes et d'identifier les confusions les plus notables.

Les indicateurs sont calculés pour toutes les années pour chaque algorithme. Les valeurs de F-Score, puis celles d'omission et commission sont successivement analysées. Afin d'identifier les confusions inter-classes, une matrice de confusion moyenne entre 13 classifications successives de 13 séries de 3 ans de 2000 à 2014 et les données de référence est établie. Les classifications sont réalisées par l'algorithme RF en configuration optimale. Les confusions mises en évidence par cette matrice seront analysés en termes de superficie (milliers d'hectares). Elles seront également cartographiées afin d'étudier leur organisation spatiale.

3 Résultats

3.1 Détermination des procédures de classification optimales

3.1.1 Choix du taux d'échantillonnage

Pour cette analyse, des classifications ont été réalisées à partir d'un jeu d'entraînement qui utilise tous les pixels avec une classe majoritaire seuillée à 50% et d'une série temporelle de NDVI non moyennée d'une année complète (2000) sans données ancillaires.

Maximum de vraisemblance

On observe, pour le maximum de vraisemblance, deux phases d'évolution différentes de la valeur de l'indice de Kappa. Pour un taux d'échantillonnage entre 0,1 et 1%, la précision connaît une augmentation rapide (+0,16). Au-delà de 1%, on observe une phase de stabilisation et à partir de 5% le Kappa n'augmente plus. On peut en déduire que cette valeur correspond au taux d'échantillonnage optimal et que les informations apportées par les pixels d'entraînement supplémentaires ne permettent pas de l'améliorer.

La variation du taux d'échantillonnage n'a pas d'influence sur le temps de calcul pour le maximum de vraisemblance, dont la valeur reste d'environ 3 minutes par classification (figure 38).

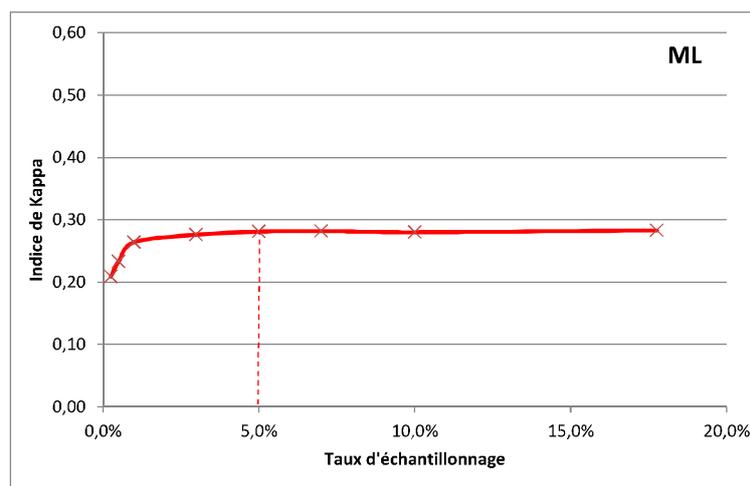


Figure 38 : Variation de la précision de classification en fonction du taux d'échantillonnage pour ML. Modalités constantes : série non moyennée de NDVI d'une année complète (2000) et taux de classe majoritaire de 50%.

Support Vector Machine

La variation des valeurs de Kappa présente 3 phases (figure 39). Une première phase de croissance est observée pour les valeurs de taux d'échantillonnage entre 0,1 et 1%. Entre 1 et 3%, la valeur de l'indice de Kappa se stabilise autour d'un maximum d'environ 0,36. Au-delà de 3%, le Kappa diminue notablement avec l'augmentation du taux d'échantillonnage. A 10%, l'indice n'est plus que de 0,26 et devient proche de 0,15 pour 17,8%. La dégradation observée est liée à un phénomène d'« overfitting »; quand le nombre de pixels d'entraînement est trop grand, SVM produit un modèle trop spécifique qui se généralise mal à l'ensemble des pixels à classer. On considère que le taux d'échantillonnage optimal pour SVM est de 3%.

On note que la variation du taux d'échantillonnage n'a aucune incidence notable sur le temps de calcul (figure 41), dont la valeur reste égale à environ 3 minutes par classification.

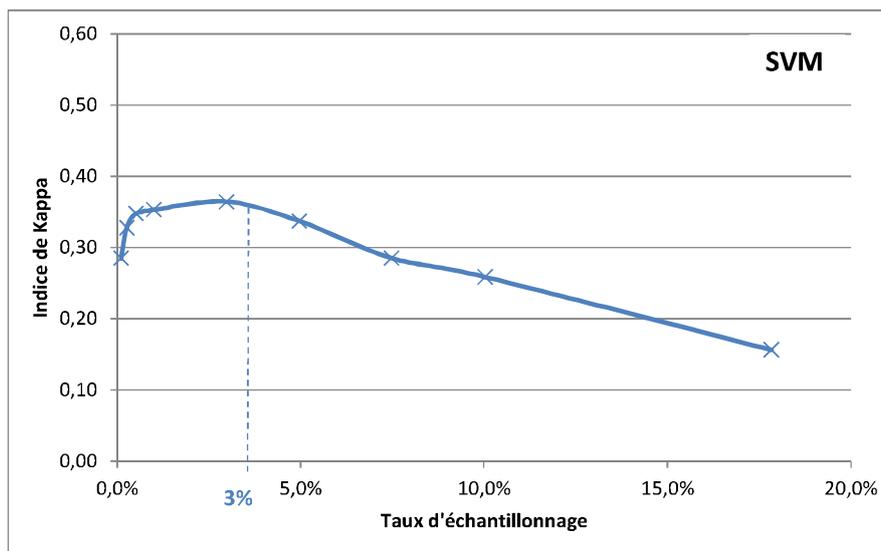


Figure 39 : Variation de la précision de classification en fonction du taux d'échantillonnage pour SVM. Modalités constantes : série non moyennée de NDVI d'une année complète (2000) et taux de classe majoritaire de 50%.

Random Forest

Comme pour ML, les valeurs de Kappa augmentent rapidement entre 0,1 et 1 % passant de 0,27 à 0,32. Au-delà de 1% les valeurs augmentent régulièrement (figure 40). La variation du taux d'échantillonnage sur cette gamme de valeurs permet d'atteindre un indice de Kappa maximal de 0,45, pour un taux d'échantillonnage de 17,8%. Ainsi, tout ajout d'information apportée par les pixels d'entraînement augmente la précision des résultats. La valeur de 17,8% devrait théoriquement être conservée comme taux d'échantillonnage optimal pour RF.

Toutefois, l'analyse du temps de calcul pour cette méthode montre que ce dernier connaît une forte croissance pour des valeurs supérieures à 5% (figure 41). Il passe ainsi d'environ 15 minutes à plus d'une heure pour un taux d'échantillonnage de 10%, pour le traitement d'une année complète, soit une série temporelle de 23 images de NDVI seulement. Au-delà de 10%, avec les moyens informatiques disponibles, les calculs sont techniquement difficiles à réaliser. Le taux d'échantillonnage optimal retenu pour la méthode RF est de 10% ; il s'agit d'un compromis entre temps de calcul et précision de classification.

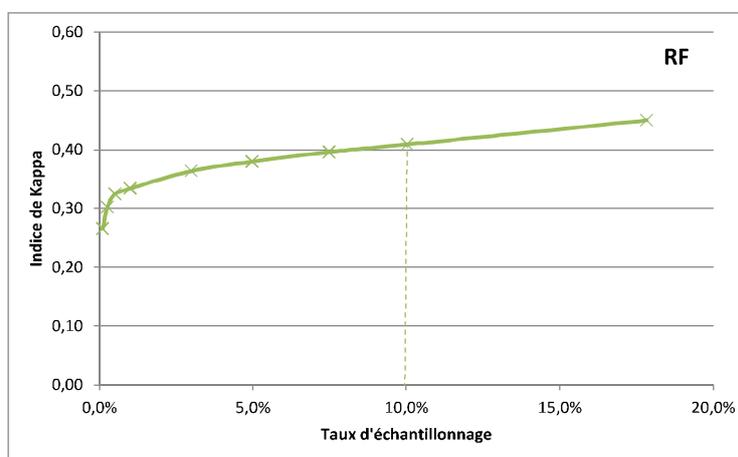


Figure 40 : Variation de la précision de classification en fonction du taux d'échantillonnage pour RF. Modalités constantes : série non moyennée de NDVI d'une année complète (2000) et taux de classe majoritaire de 50%.

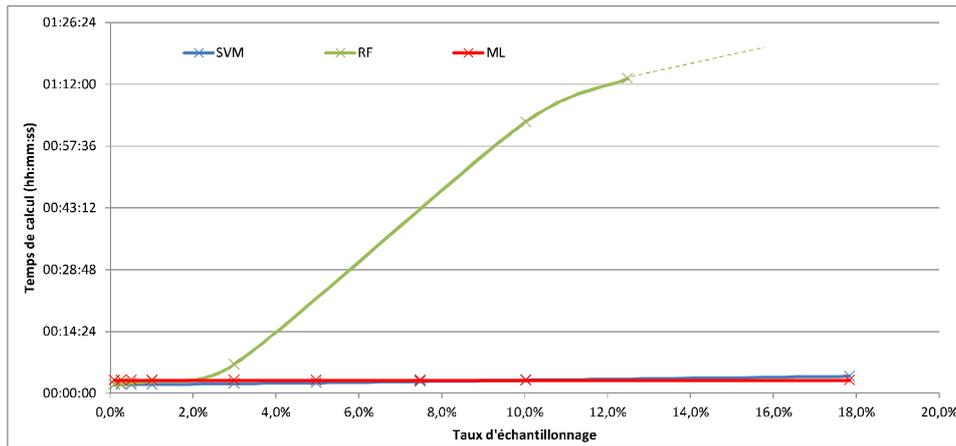


Figure 41 : Variation du temps de calcul en fonction du taux d'échantillonnage pour les 3 méthodes de classification.

Conclusion

On peut constater que les algorithmes SVM, ML et RF ne nécessitent pas la même quantité de pixels d'entraînement pour leur fonctionnement optimal. Dans tous les cas il existe un seuil minimal de taux d'échantillonnage pour les 3 algorithmes, ici 1% (figure 42). Au-delà de ce seuil le comportement des algorithmes est différent. Pour ML la progression est très faible et il n'y a pas vraiment intérêt à augmenter le taux d'échantillonnage. Pour SVM, un deuxième seuil est identifiable, ici 3 %, au-delà duquel la précision se dégrade avec l'augmentation du taux d'échantillonnage. Pour RF, on a une progression régulière qui confirme l'intérêt d'utiliser le maximum de références disponibles.

On remarque que jusqu'à 8% ML présente des valeurs de Kappa nettement inférieures aux deux autres algorithmes et SVM et RF sont similaires jusqu'au seuil de 3 % et au-delà RF est meilleur.

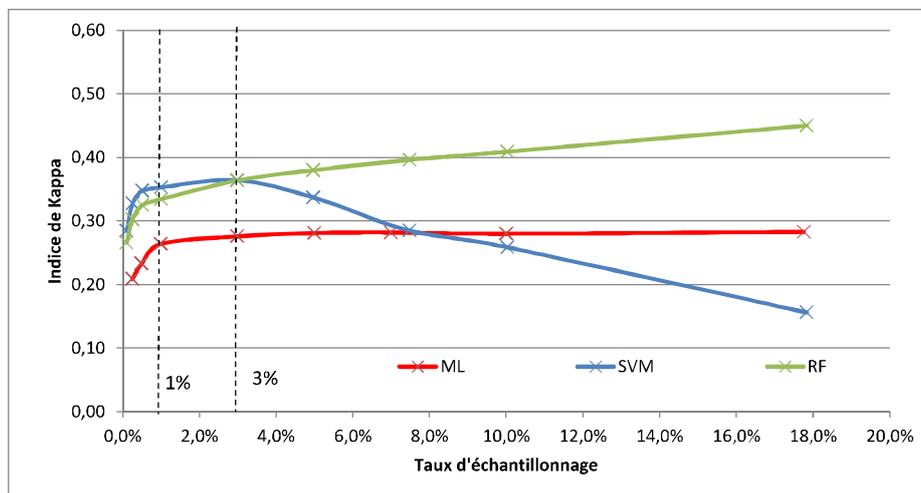


Figure 42 : Variation de l'indice de Kappa en fonction du taux d'échantillonnage pour les trois méthodes de classification.

Le tableau 23 présente les valeurs optimales de taux d'échantillonnage définies pour chaque méthode de classification.

Tableau 23 : Valeurs optimales du taux d'échantillonnage retenues pour les 3 méthodes de classification.

Algorithme	Taux d'échantillonnage optimal
ML	5%
SVM	3%
RF	10%

3.1.2 Choix du seuil de taux de classe majoritaire

Les classifications ont été réalisées en faisant varier le seuil du taux de classe majoritaire entre 50 et 100% et en fixant les autres caractéristiques : valeur optimale du taux d'échantillonnage, série de NDVI non moyennée d'une année complète (2000) et pas de données ancillaires. Les résultats obtenus pour les trois algorithmes indiquent que la variation du seuil de taux de classe majoritaire des pixels d'entraînement n'a qu'une faible influence sur la précision de classification (figure 43). Il faut rappeler que le calcul du taux de classe majoritaire est réalisé à partir des polygones des cartes forestières. On peut supposer que ces limites cartographiques ne rendent pas complètement compte de l'hétérogénéité réelle des formations végétales au sol.

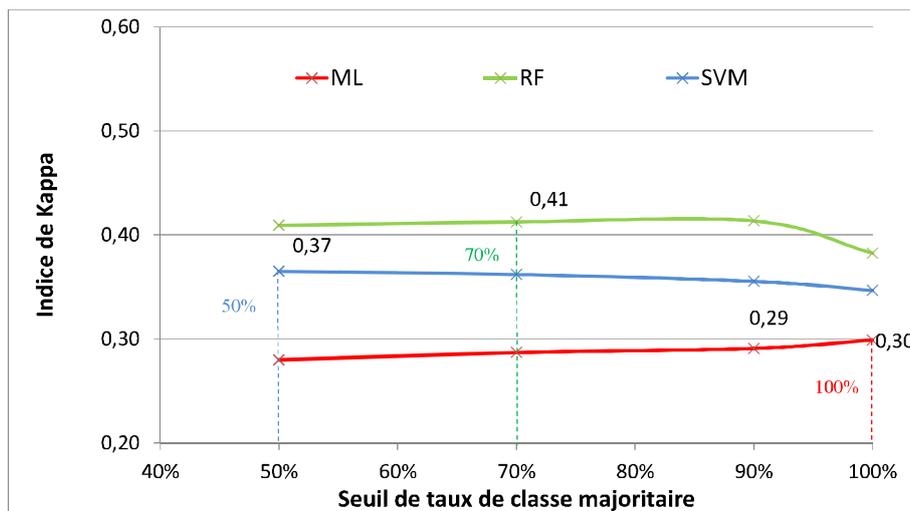


Figure 43 : Evolution de l'indice de Kappa en fonction du taux de classe majoritaire pour les trois méthodes en configuration optimale du taux d'échantillonnage.

On peut cependant fixer les seuils pour lesquels on obtient le meilleur Kappa.

Pour ML, la valeur maximale de l'indice de Kappa est de 0,30 et est atteinte lorsque l'on prend la totalité des pixels d'entraînement inclus à 100% dans la délimitation des formations végétales. C'est donc ce taux qui sera retenu comme valeur optimale (tableau 6).

Pour SVM, on note au contraire une légère baisse avec un minimum mesuré pour le seuil de 100%. La précision maximale est observée pour le seuil de 50% avec une valeur de Kappa de 0,36. La valeur optimale retenue est donc 50% (tableau 6).

Pour RF, la valeur maximale de l'indice de Kappa est atteinte pour 70% de classe majoritaire. On peut noter qu'au-delà du seuil de 90%, l'indice de Kappa diminue sensiblement. Ceci est dû à la diminution

du nombre de pixels d'entraînement disponibles car, pour le seuil de 100%, le taux d'échantillonnage est limité à 6% au lieu des 10% définis précédemment. Le seuil optimal pour RF est fixé à 70% (tableau 24).

Les valeurs d'indice de Kappa sont les plus élevées pour la méthode RF et sont proches de 0,41. Les valeurs les plus basses correspondent à la méthode ML et sont proches de 0,29. La précision obtenue par SVM est intermédiaire et égale à environ 0,36.

L'observation des temps de calcul nécessaires à la réalisation des classifications indique que la variation du seuil du taux de classe majoritaire n'a aucune influence sur cet élément quel que soit l'algorithme considéré.

Tableau 24 : Valeurs optimales du taux d'échantillonnage et du taux de classe majoritaire retenues pour les 3 algorithmes.

Algorithme	Taux d'échantillonnage optimal	Seuil optimal du taux de classe majoritaire	Indice de Kappa
ML	5%	100%	0,30
SVM	3%	50%	0,37
RF	10%	70%	0,41

3.1.3 Choix de l'organisation des séries

Les classifications ont été réalisées en faisant varier l'organisation temporelle et la composition radiométrique des séries et en fixant les autres caractéristiques : valeurs optimales du taux d'échantillonnage et du seuil de taux de classe majoritaire et pas de données ancillaires. Dans les paragraphes suivants on commentera les variations de Kappa liées à l'organisation temporelle des séries : durée (1, 2 ou 3 ans), pour chaque série (complète, hors hiver et 3 dates) en prenant en compte soit l'ensemble des images (non moyennées) soit les moyennes calculées sur 2 ou 3 ans (moyennées).

3.1.3.1 La série temporelle de NDVI

Maximum de vraisemblance

Pour les données non moyennées (figure 44), l'allongement de la durée a un effet positif sur les valeurs de Kappa. Le passage de 1 à 3 ans permet d'augmenter les valeurs de Kappa d'environ 0,05 pour les 3 séries.

Les valeurs obtenues pour la série complète et hors hiver sont peu différentes. Par contre elles sont systématiquement supérieures à la série 3 dates.

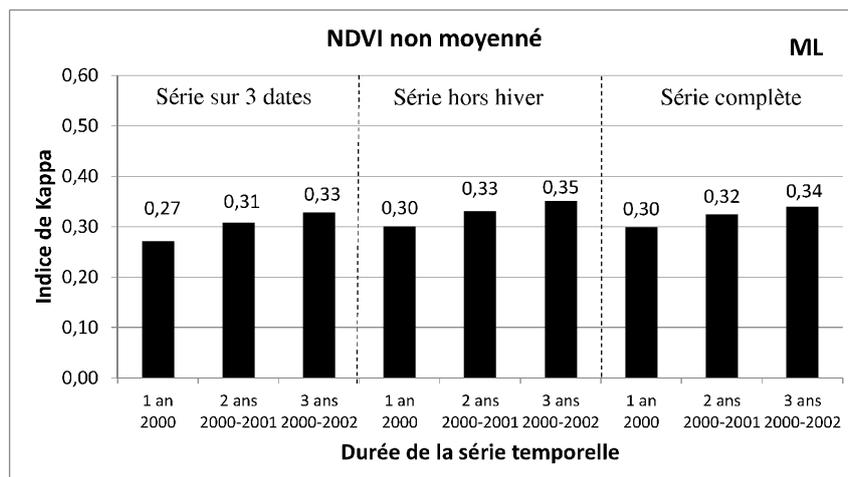


Figure 44 : Valeur de l'indice de Kappa pour la série temporelle de NDVI non moyennée pour la méthode du maximum de vraisemblance (période 2000-2002).

Pour les données moyennées (figure 45), l'allongement de la durée a un effet négligeable sur les valeurs de Kappa. Comme précédemment, les valeurs obtenues pour la série complète et hors hiver sont peu différentes mais elles sont systématiquement supérieures à la série 3 dates. Par contre dans tous les cas les valeurs de Kappa obtenues avec les données moyennées sont légèrement inférieures aux données non moyennées, les écarts vont de 0,01 à 0,04.

La série qui produit le meilleur résultat est la série 3 ans, hors hiver non moyennée.

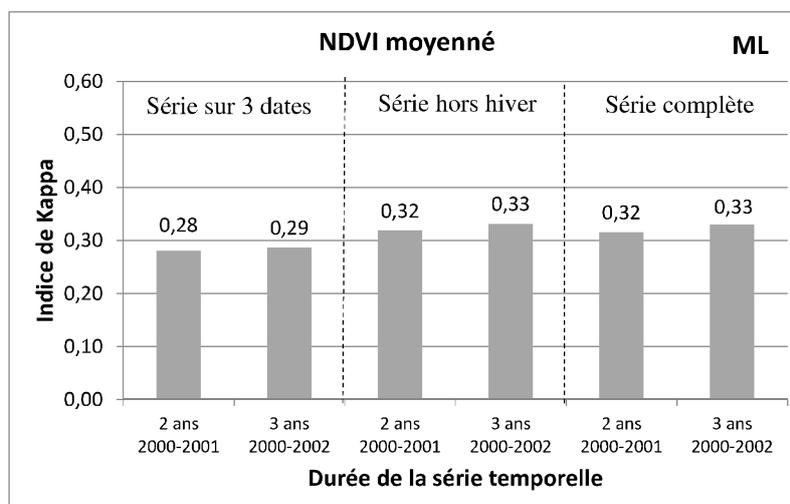


Figure 45: Valeur de l'indice de Kappa pour la série temporelle de NDVI moyennée pour la méthode du maximum de vraisemblance (période 2000-2002).

Support Vector Machine

Les résultats obtenus avec cet algorithme présentent les mêmes variations (figures 46 et 47). On note cependant des écarts un peu plus importants.

Pour le passage de 1 à 3 ans, les écarts de Kappa vont de 0,06 à 0,09 selon les 3 séries.

Les différences entre, d'une part les séries complètes et hors hiver et, d'autre part, les séries 3 dates sont aussi plus marquées.

Si on compare les cas donnant les résultats extrêmes, on observe ainsi un écart d'indice de Kappa d'environ 0,15 entre la série de NDVI non moyennée complète de trois ans et la série de NDVI non moyennée sur trois dates d'un an.

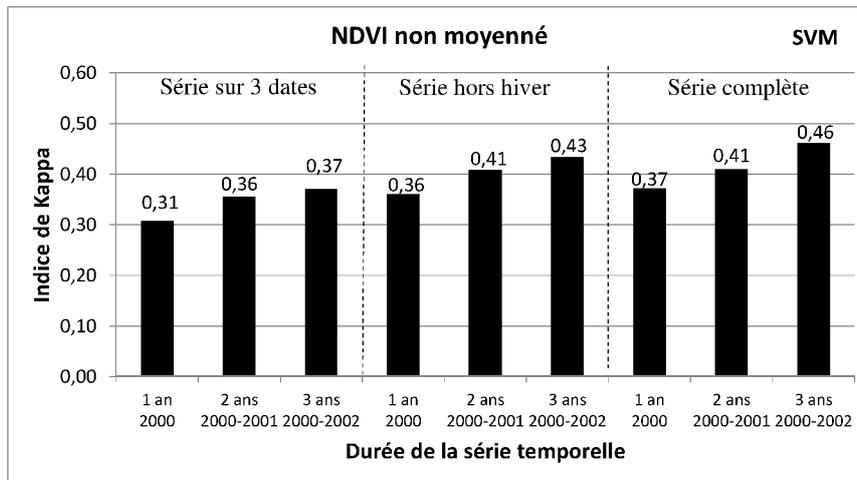


Figure 46 : Valeur de l'indice de Kappa pour la série temporelle de NDVI non moyennée pour la méthode SVM (période 2000-2002).

On retrouve les mêmes différences entre les séries moyennées et non moyennées qu'avec ML avec des écarts un peu plus importants. Ils peuvent atteindre 0,09 dans le cas des séries complètes 3 ans. La série qui produit le meilleur résultat est la série 3 ans, complète non moyennée.

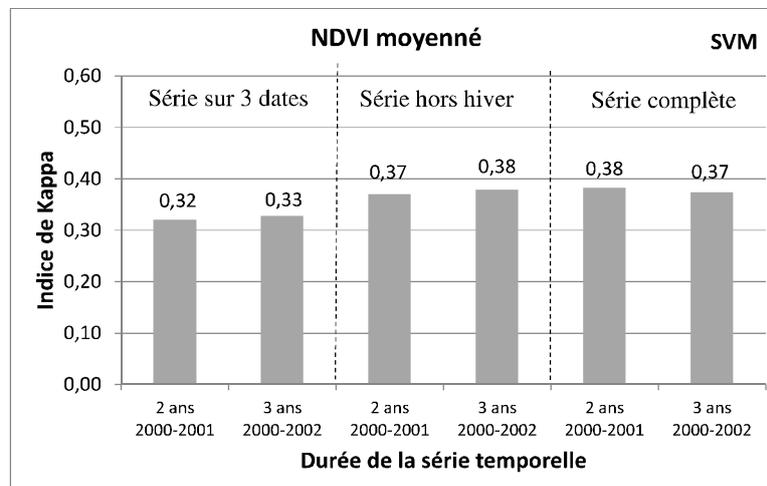


Figure 47 : Valeur de l'indice de Kappa pour la série temporelle de NDVI moyennée pour la méthode SVM (période 2000-2002).

Random Forest

Les résultats obtenus avec RF présentent des caractéristiques similaires à ceux de SVM et ML (figures 48 et 49) avec des écarts cependant encore plus marqués.

Pour le passage de 1 à 3 ans, les écarts de Kappa vont de 0,05 à 0,10 selon les 3 séries.

On observe également des différences importantes entre, d'une part les séries complètes et hors hiver et, d'autre part, les séries 3 dates.

L'écart le plus extrême est ici aussi entre la série de NDVI non moyennée complète de trois ans et la série de NDVI non moyennée sur trois dates d'un an. Il est d'environ 0,19.

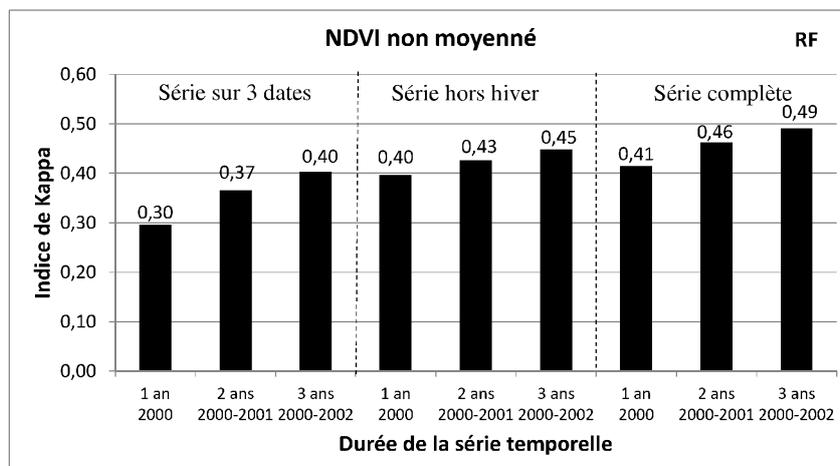


Figure 48 : Valeur de l'indice de Kappa pour la série temporelle de NDVI non moyennée pour la méthode RF (période 2000-2002).

Les différences entre les séries moyennées et non moyennées sont relativement faibles mais peuvent atteindre 0,08 dans le cas des séries 3 dates.

Comme pour SVM, on considère que la série 3 ans complète non moyennée produit le meilleur résultat.

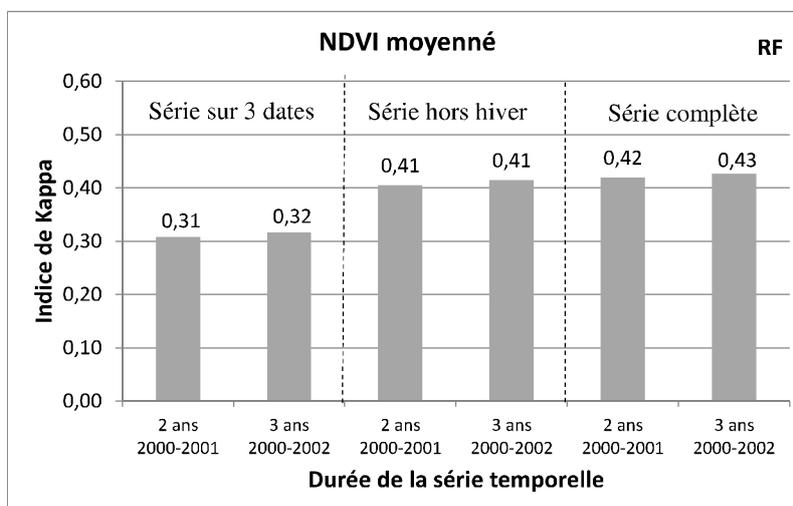


Figure 49 : Valeur de l'indice de Kappa pour la série temporelle de NDVI moyennée pour la méthode RF (période 2000-2002).

Synthèse

Les résultats obtenus pour RF et SVM mettent particulièrement en évidence l'intérêt d'utiliser la série temporelle la plus complète. Les résultats sont systématiquement moins bons avec les séries 3 dates. On peut supposer que ces 3 dates ne sont pas suffisantes pour caractériser le cycle phénologique. Inversement, la prise en compte complète du cycle annuel peut expliquer l'amélioration de la précision de classification.

On peut faire la même observation pour la durée. Les résultats pour une durée de 3 ans sont meilleurs que pour 1 seule année. On peut en déduire que la prise en compte de la variabilité du cycle phénologique sur plusieurs années consécutives est une information utile pour la classification.

Les résultats obtenus pour ML montrent que la durée influence les résultats de la même manière que pour RF et SVM. Cependant la série hors hiver semble plus favorable à ML. On peut supposer que l'élimination des images d'hiver limite l'effet des nuages et de la neige particulièrement présents sur notre site d'étude durant cette saison. Il semblerait que les méthodes SVM et RF n'y soient pas sensibles.

Pour les 3 algorithmes, l'hypothèse d'améliorer les résultats en utilisant des données moyennées, afin de limiter les erreurs dues à la qualité des images, n'est pas validée puisque les résultats sont systématiquement moins bons. Ceci s'est également vérifié au cours des étapes suivantes de l'analyse. Nous n'avons donc pas jugé utile de présenter les résultats issus des séries moyennées dans la suite de ce mémoire.

On a également mis en évidence que les résultats sont systématiquement meilleurs avec RF, ML étant l'algorithme le moins efficace.

Le tableau 25 récapitule l'organisation optimale des séries de NDVI pour les 3 algorithmes.

Tableau 25 : Composition optimale de la série temporelle de NDVI pour les 3 méthodes de classification.

Caractéristiques fixées	Série optimale	Durée optimale	Indice de Kappa NDVI
ML Taux échantillonnage : 5% Taux de CM : 100%	Série hors hiver non moyennée	3 ans	0,35
SVM Taux échantillonnage : 3% Taux de CM : 50%	Série complète non moyennée	3 ans	0,46
RF Taux échantillonnage : 10% Taux de CM : 70%	Série complète non moyennée	3 ans	0,49

3.1.3.2 La série temporelle de EVI

L'analyse de l'organisation temporelle de l'indice EVI montre que les valeurs de Kappa mesurées sont équivalentes ou légèrement inférieures à celles observées pour le NDVI (figures 50 à 52). On constate également que les facteurs d'amélioration des classifications sont les mêmes que pour les deux indices de végétation.

L'effet de la durée sur les valeurs de Kappa obtenues avec l'EVI varient de 0,06 à 0,13, ce qui est légèrement plus élevé que ce qui a été observé pour le NDVI, avec des valeurs variant de 0,02 à 0,10. Pour l'effet des séries, les écarts observés sont du même ordre de grandeur. Ils varient entre 0,02 et 0,11, pour l'EVI comme pour le NDVI.

On peut en conclure que le changement d'indice de végétation n'a pas d'influence notable sur la qualité de classification. L'hypothèse initiale que la moindre saturation de l'EVI permettrait une meilleure caractérisation des classes n'est pas vérifiée.

La durée optimale est de 3 ans de données non moyennées. Pour RF et SVM l'optimum est obtenu avec la série complète. Pour le ML, on confirme également que la série hors hiver est l'optimum.

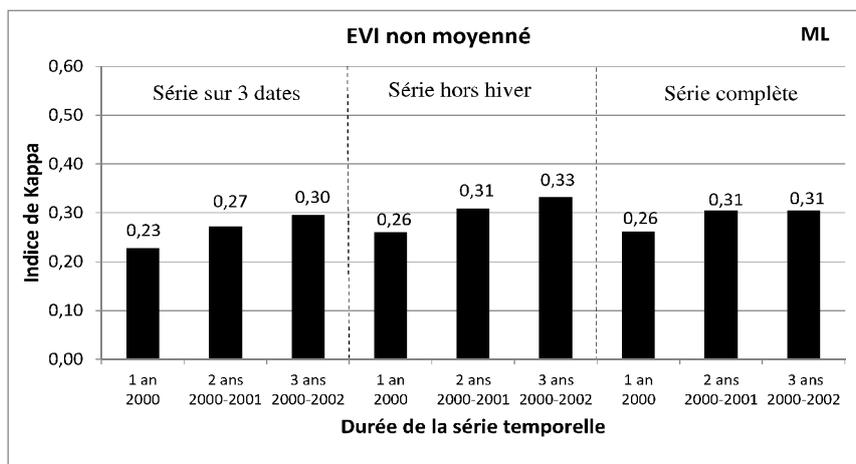


Figure 50 : Valeur de l'indice de Kappa selon la durée de la série temporelle d'EVI non moyennée pour la méthode ML (période 2000-2002).

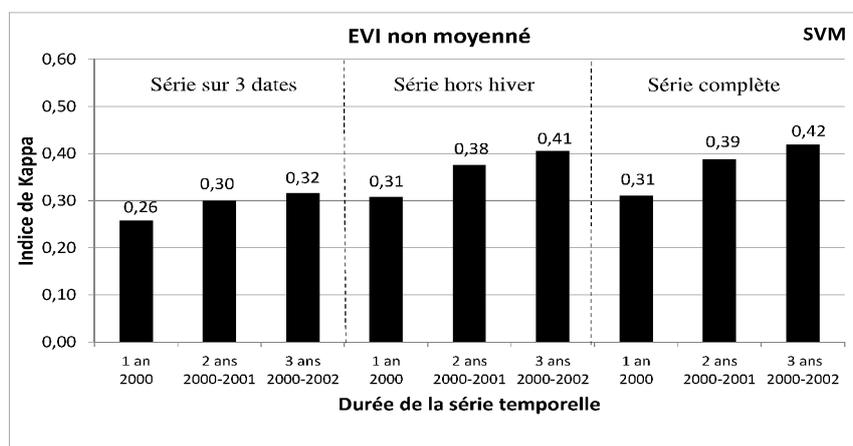


Figure 51 : Valeur de l'indice de Kappa selon la durée de la série temporelle d'EVI non moyennée pour la méthode SVM (période 2000-2002).

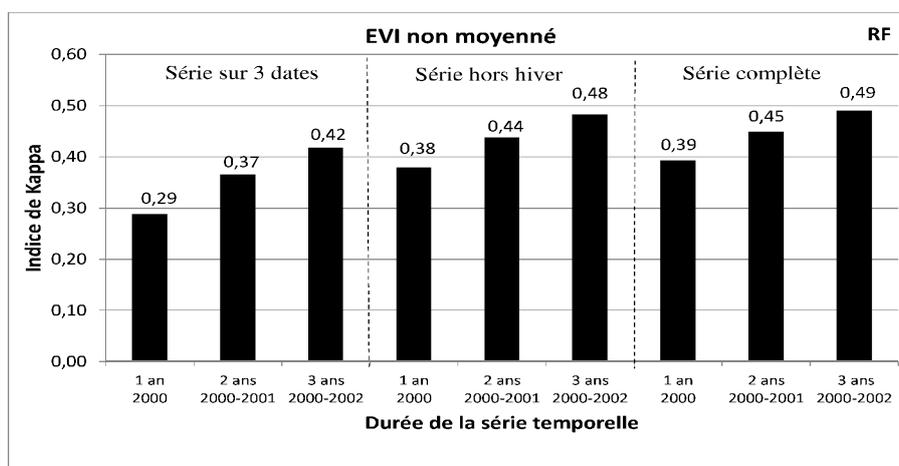


Figure 52 : Valeur de l'indice de Kappa selon la durée de la série temporelle d'EVI non moyennée pour la méthode Random Forest (période 2000-2002).

Le tableau 26 récapitule les meilleurs résultats obtenus pour les séries temporelles de NDVI et d'EVI pour les 3 algorithmes. Il confirme que les précisions de classification les plus élevées sont obtenues par RF, quel que soit l'indice de végétation utilisé. Pour ML et SVM, on peut noter que les classifications réalisées avec le NDVI sont de meilleure qualité que celles utilisant l'EVI.

Tableau 26 : Composition optimale de la série temporelle d'EVI et de NDVI pour les 3 algorithmes (CM : classe majoritaire).

Caractéristiques fixées	Série optimale	Durée optimale	Indice de Kappa EVI	Indice de Kappa NDVI
ML Taux échantillonnage : 5% Taux de CM : 100%	Série hors hiver non moyennée	3 ans	0,33	0,35
SVM Taux échantillonnage : 3% Taux de CM : 50%	Série complète non moyennée	3 ans	0,42	0,46
RF Taux échantillonnage : 10% Taux de CM : 70%	Série complète non moyennée	3 ans	0,49	0,49

La précision maximale de classification est de 0,49 et est atteinte par la méthode Random Forest pour une série complète non moyennée sur 3 ans d'EVI ou de NDVI. Toutefois, le NDVI donnant des précisions légèrement plus importantes que l'EVI pour les 2 autres méthodes, on ne présentera que le NDVI pour la suite de l'analyse. De la même façon, par la suite on ne commentera que les séries optimales : complètes pour RF et SVM, et hors hiver, pour ML.

3.1.3.3 La série temporelle de bandes spectrales

Les résultats présentés dans cette partie ont été obtenus à partir des caractéristiques de données d'entrée suivantes :

- le taux d'échantillonnage du jeu d'entraînement optimal pour chaque méthode (5% pour ML, 3% pour SVM, 10% pour RF),
- le seuil du taux de classe majoritaire du jeu d'entraînement optimal pour chaque méthode (100% pour ML, 50% pour SVM, 70% pour RF),
- des séries non moyennées complètes pour RF et SVM, et hors hiver, pour ML,
- des durées de 1 à 3 ans.

On a fait varier la composition radiométrique des séries en utilisant les bandes spectrales : R+NIR et R+NIR+MIR.

Pour la comparaison, on a reporté également les résultats obtenus pour le NDVI.

Maximum de vraisemblance

Comme précédemment, on montre l'effet de la durée sur la précision de la classification (figure 53). L'utilisation de la durée de 3 ans permet un gain de valeur de Kappa entre 0,06 et 0,07, pour les bandes spectrales, similaire à celui du NDVI : 0,05.

Les bandes spectrales apportent une nette amélioration de précision par rapport au NDVI, de l'ordre de 0,12. On constate que l'ajout du MIR augmente légèrement le Kappa, d'environ 0,1. La qualité maximale de classification pour le maximum de vraisemblance est observée pour la série complète non moyennée R+NIR+MIR de trois ans et est égale à 0,48.

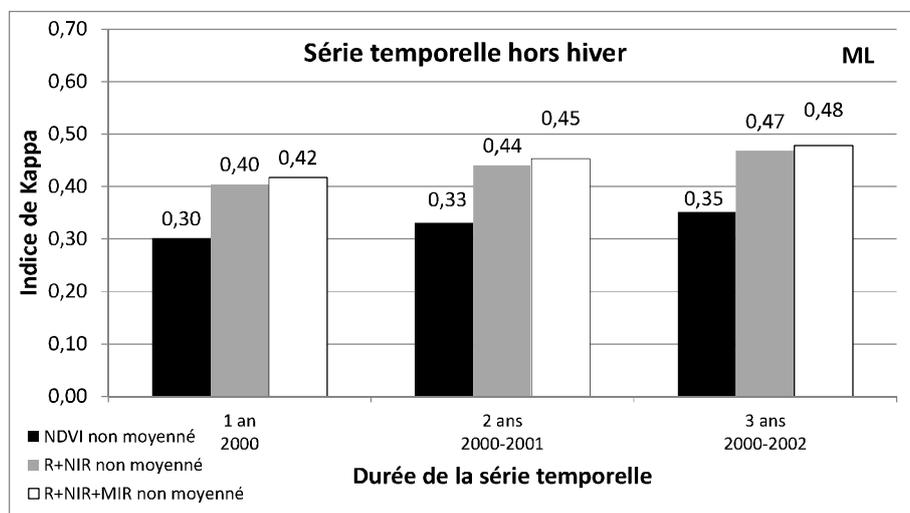


Figure 53 : Valeur de l'indice de Kappa selon la durée pour le maximum de vraisemblance et pour les séries hors hiver non moyennées de NDVI, R+NIR et R+NIR+MIR (période 2000-2002).

Support Vector Machine

On peut faire le même constat que précédemment, l'augmentation de la durée améliore les résultats de manière aussi significative (figure 54). Le gain est de 0,06 pour les bandes spectrales alors qu'il est de 0,09 pour le NDVI.

On constate un apport notable des séries R+NIR et R+NIR+MIR par rapport aux séries de NDVI car elles permettent un gain de 0,11 à 0,13. Les valeurs s'échelonnent entre 0,40 et 0,47 pour le R+NIR et entre 0,42 et 0,48 pour le R+NIR+MIR, ce qui met en évidence l'effet mineur de l'ajout de la réflectance MIR.

La valeur maximale de précision de classification est de 0,55 et est obtenue pour la série complète non moyennée R+NIR+MIR de 3 ans.

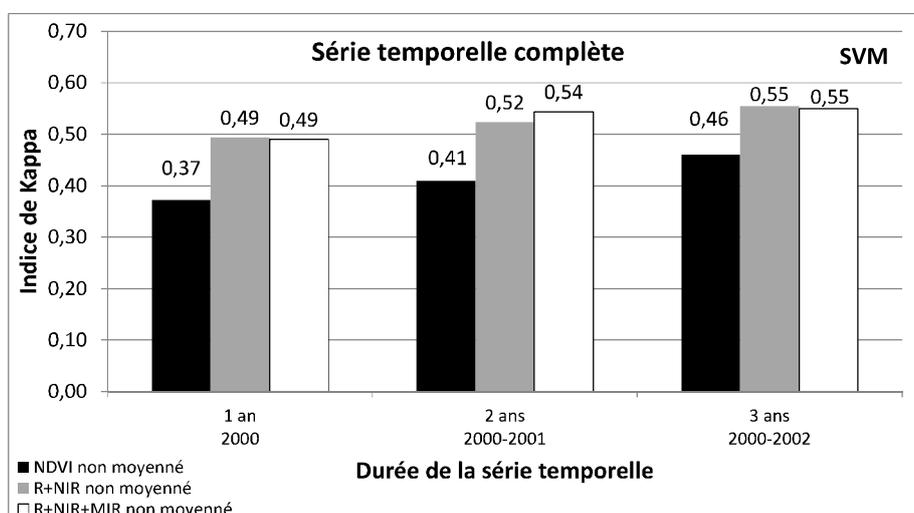


Figure 54 : Valeur de l'indice de Kappa selon la durée pour la méthode SVM et pour les séries complètes non moyennées de NDVI, R+NIR et R+NIR+MIR (période 2000-2002).

Random Forest

L'influence de la durée est moins nette que dans les cas précédents. Le gain de valeur de Kappa est de seulement 0,03 pour les bandes spectrales, alors qu'il atteint 0,08 pour le NDVI (figure 55).

Pour RF, comme pour ML et SVM, les résultats obtenus mettent en évidence l'apport des bandes spectrales. Le gain de précision par rapport au NDVI est important, il atteint 0,17 pour la durée de 1 an. On constate une fois de plus que l'ajout du MIR aux bandes spectrales n'améliore que très faiblement la précision.

La précision maximale observée pour la méthode Random Forest est de 0,61 et correspond à la série complète non moyennée R+NIR+MIR sur 3 ans.

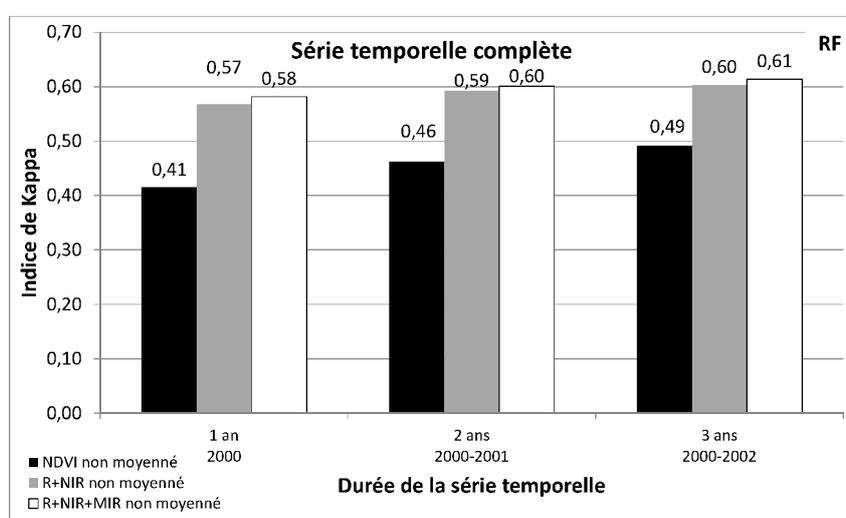


Figure 55 : Valeur de l'indice de Kappa selon la durée pour la méthode Random Forest et pour les séries complètes non moyennées de NDVI, R+NIR et R+NIR+MIR (période 2000-2002).

Les résultats obtenus à partir de la classification des bandes spectrales permettent de définir les configurations qui produisent les meilleurs résultats, pour les 3 algorithmes étudiés (tableau 27).

Tableau 27 : Configuration optimale pour les 3 algorithmes.

Caractéristiques fixées	Composition optimale	Série optimale	Durée optimale	Indice de Kappa
ML Taux échantillonnage : 5% Taux de CM : 100%	R+NIR+MIR	Série hors hiver non moyennée	3 ans	0,48
SVM Taux échantillonnage : 3% Taux de CM : 50%	R+NIR+MIR	Série complète non moyennée	3 ans	0,55
RF Taux échantillonnage : 10% Taux de CM : 70%	R+NIR+MIR	Série complète non moyennée	3 ans	0,61

La comparaison des résultats obtenus confirme que RF permet d'atteindre les précisions de classification les plus élevées. La précision de classification maximale est égale à 0,61 et est atteinte pour la série complète non moyennée R+NIR+MIR de 3 ans. Pour SVM et ML, les valeurs d'indice de Kappa atteintes sont respectivement de 0,55 et 0,48.

Dans tous les cas, l'augmentation de la durée est un facteur d'amélioration non négligeable même s'il est plus significatif pour ML et SVM que pour RF. On retiendra donc cette durée dans la procédure de classification considérée comme optimale.

On observe également dans tous les cas une très faible amélioration de la précision liée à l'ajout du MIR aux bandes spectrales. Le gain de Kappa ne dépasse pas 0,02. On peut supposer que l'information apportée par la bande spectrale MIR est de moins bonne qualité. La résolution spatiale n'est que de 500 m et cette longueur d'onde est plus sensible aux perturbations atmosphériques et à la neige. On a cependant choisi de la conserver dans la composition des séries temporelles.

3.1.3.4 Apport des données ancillaires

L'ensemble des tests de cette étape ont été réalisés à l'aide des 3 procédures de classification dans leur configuration optimale de jeu d'entraînement, d'organisation temporelle et de composition radiométrique (tableau 27).

On observe pour les algorithmes ML et SVM que l'ajout de l'altitude n'améliore que faiblement les résultats, générant un gain de Kappa de 0,02 d'indice de Kappa pour les bandes spectrales et pour le NDVI. Pour RF on ne constate aucune amélioration, toutefois l'ajout de l'altitude est conservé dans la configuration optimale des séries temporelles.

Pour les 3 algorithmes, la prise en compte du rayonnement solaire global n'a quant à lui aucune incidence sur la précision de classification, il n'est pas conservé.

3.1.3.5 Synthèse

L'ensemble de ces étapes d'analyse confirme que des gains de précision, d'importance variable, peuvent être obtenus en fonction des choix que l'on fait pour la mise en place de la procédure de classification.

Par le paramétrage :

Pour SVM, l'optimisation des paramètres C et γ est indispensable. Elle a pu être réalisée facilement à chaque étape.

Pour RF, c'est essentiellement le réglage du nombre de variables qui a un impact sur la qualité des résultats (+ 0,1 de Kappa).

Pour ML aucun réglage n'a été effectué, mais il serait possible de travailler avec les probabilités a priori.

Par l'optimisation du jeu d'entraînement :

Comme attendu, le taux d'échantillonnage a un effet important sur la qualité des classifications. On peut rappeler que pour les 3 algorithmes il existe un seuil minimal de taux d'échantillonnage, d'environ 1%. Pour SVM, un deuxième seuil a été identifié vers 3 %, au-delà duquel la précision se dégrade avec l'augmentation du taux d'échantillonnage.

Concernant le seuil de taux de classe majoritaire, aucune influence sur la qualité des résultats n'a été démontrée.

Par l'organisation temporelle et la composition radiométrique des séries d'images :

La figure 56 présente les valeurs de Kappa les plus élevées obtenues et permet de montrer l'évolution progressive du gain de précision parallèlement à la modification des caractéristiques des séries d'images.

Au final quatre facteurs d'amélioration sont identifiés :

- l'effet série, par le passage de la série composée de 3 dates à la série complète ou hors hiver, avec un effet plus marqué pour RF et SVM que pour ML,
- l'effet durée, par la prise en compte de 3 ans au lieu d'une seule année et lorsque les images ne sont pas moyennées ; dans ce cas l'amélioration est aussi plus marquée pour RF et SVM que pour ML,
- l'effet lié à l'utilisation des bandes spectrales au lieu de l'indice de végétation ; l'amélioration est conséquente pour les 3 algorithmes, et encore plus importante pour ML
- l'effet de l'ajout de l'altitude ; l'amélioration concerne uniquement ML.

Le gain maximal par l'effet cumulé de ces différentes caractéristiques des séries est de 0,32 pour RF, 0,25 pour SVM et 0,22 pour ML.

On peut noter que les améliorations suivent l'augmentation du nombre d'images et donc de la quantité d'information utilisée.

Par le choix de l'algorithme

La synthèse confirme que les niveaux de précision obtenus sont systématiquement plus élevés avec RF, et systématiquement plus faibles avec ML. Si l'écart est quasi inexistant pour la première configuration, il devient rapidement important et atteint parfois 0,15, entre ML et RF. Il est de 0,12 pour la dernière configuration testée.

Les valeurs de Kappa obtenues à partir des placettes sont plus élevées (tableau 28) et atteignent 0,73 pour RF, 0,70 pour SVM et 0,66 ML.

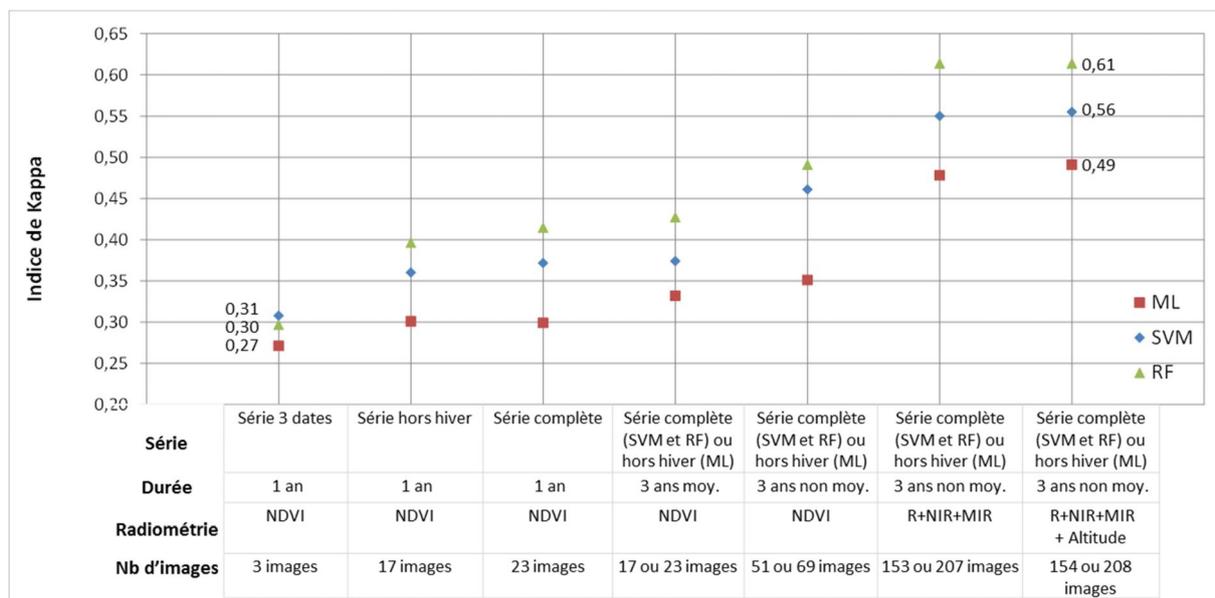


Figure 56 : Evolution de l'indice de Kappa en fonction de l'organisation temporelle et de la composition radiométrique des séries, pour les 3 algorithmes de classification.

Le tableau suivant récapitule les configurations optimales que l'on peut retenir à partir des tests réalisés avec les 3 algorithmes et sur notre site d'étude (tableau 28).

Tableau 28 : Comparaison des précisions de classification maximales obtenues pour les 3 méthodes à partir de leur configuration optimale.

Algorithme	Configuration optimale du jeu d'entraînement	Organisation temporelle et composition spectrale optimales des séries	Indice de Kappa (données de référence)	Indice de Kappa (placettes IFN)
ML	Taux d'échantillonnage : 5% Taux de CM : 100%	Série hors hiver R+NIR+MIR non moyennée sur 3 ans + Altitude	0,49	0,66
SVM	Taux d'échantillonnage : 3% Taux de CM : 50%	Série complète R+NIR+MIR non moyennée sur 3 ans + Altitude	0,55	0,70
RF	Taux d'échantillonnage : 10% Taux de CM : 70%	Série complète R+NIR+MIR non moyennée sur 3 ans + Altitude	0,61	0,73

3.2 Interprétation des résultats de classification

3.2.1 Analyse temporelle et spatiale des résultats

3.2.1.1 Variabilité temporelle de la qualité des classifications

La variabilité temporelle des résultats a été étudiée pour la configuration optimale de chaque procédure de classification et pour l'ensemble des années disponibles (de 2000 à 2014) à partir des séries 3 ans (tableaux 29 et 30). Les valeurs d'indice de Kappa calculées sont stables. On n'observe pas d'année atypique ni de tendance. L'écart observé précédemment entre les trois algorithmes se vérifie pour l'ensemble des années. Les valeurs moyennes de Kappa pour ML, SVM et RF sont respectivement de 0,49, 0,55 et 0,61 sur les données de référence, et de 0,64, 0,71 et 0,74 sur les placettes IFN. Les écart-types sont inférieurs à 0,01.

Tableau 29: Evolution temporelle de la valeur de l'indice de Kappa, calculé à partir de l'ensemble des pixels classés, pour chaque procédure de classification et pour la période 2000-2014.

Méthode de classification	2000	2001	2002	2003	2004	2005	2006	2007	2008	2009	2010	2011	2012	2013	2014	moy.	std
RF	0,61	0,61	0,62	0,61	0,61	0,60	0,60	0,60	0,60	0,60	0,60	0,60	0,60	0,60	0,60	0,61	0,005
SVM	0,55	0,55	0,56	0,56	0,55	0,55	0,55	0,55	0,55	0,55	0,55	0,55	0,55	0,55	0,55	0,55	0,002
ML	0,49	0,49	0,49	0,48	0,49	0,49	0,49	0,49	0,49	0,49	0,49	0,49	0,49	0,48	0,49	0,49	0,003

Tableau 30 : Evolution temporelle de la valeur de l'indice de Kappa, calculé à partir des placettes, pour chaque procédure de classification et pour la période 2000-2014.

Méthode de classification	2000	2001	2002	2003	2004	2005	2006	2007	2008	2009	2010	2011	2012	2013	2014	moy.	std
RF	0.73	0.74	0.74	0.74	0.75	0.74	0.74	0.74	0.73	0.74	0.73	0.73	0.74	0.74	0.74	0.74	0.005
SVM	0.70	0.70	0.72	0.73	0.71	0.71	0.71	0.70	0.71	0.71	0.72	0.70	0.71	0.71	0.71	0.71	0.007
ML	0.64	0.64	0.63	0.64	0.64	0.65	0.65	0.64	0.63	0.62	0.65	0.64	0.64	0.64	0.64	0.64	0.008

Les valeurs de F-Score, calculées pour chaque classe et pour toutes les séries 3 ans, montrent qu'il existe de fortes différences entre les classes. Les moyennes, pour toutes les classifications de 2000 à 2014, des valeurs de F-score varient de 25 à 75% pour ML, de 30 à 81% pour SVM et de 47 à 80% pour RF (tableau 31). On retrouve ici aussi la différence de qualité entre les algorithmes. Par contre pour chaque classe, les écarts types des valeurs de F-Score de 2000 à 2014 sont faibles. Ils varient de 0,3 à 1,9%, montrant la stabilité des résultats obtenus par classe, et l'on n'observe pas de différence entre les algorithmes. Les résultats par classe sont détaillés plus loin. La stabilité temporelle des résultats globaux et par classe nous permet d'utiliser, la moyenne des valeurs sur la période 2000-2014 pour analyser ensuite certains cas.

Tableau 31 : Amplitude des moyennes et des écarts-types des séries de valeurs de l'indice F-Score, calculée à partir de l'ensemble des pixels classés, pour chaque procédure de classification et pour la période 2000-2014.

Méthode de classification	Amplitude des moyennes de F-Score par classe 2000-2014	Amplitude des écarts types de F-Score par classe 2000-2014
RF	de 47 à 80%	de 0,3 à 1,5%
SVM	de 30 à 81%	de 0,3 à 1,9%
ML	25 à 75%	de 0,4 à 1,8%

3.2.1.2 Variabilité temporelle et spatiale des proportions de pixels bien classés

La validation sur l'ensemble des pixels classés permet de cartographier les similarités et les différences entre la carte forestière de référence et les classifications. Les cartes des classifications pour les trois algorithmes (figure 57) montrent la répartition spatiale des pixels bien classés et nous permettent de faire deux constatations importantes.

Premièrement, cette répartition n'est pas aléatoire. Les zones de piémont semblent généralement mal classées, et plus particulièrement sur le versant espagnol. Alors que les zones de hautes altitudes du centre de la zone d'étude et la majeure partie du Pays Basque, à l'ouest, sont plutôt bien classées.

Deuxièmement, les surfaces bien classées augmentent visiblement quand on observe les classifications réalisées avec ML, puis SVM et RF. Ce qui est cohérent avec les indicateurs calculés précédemment.

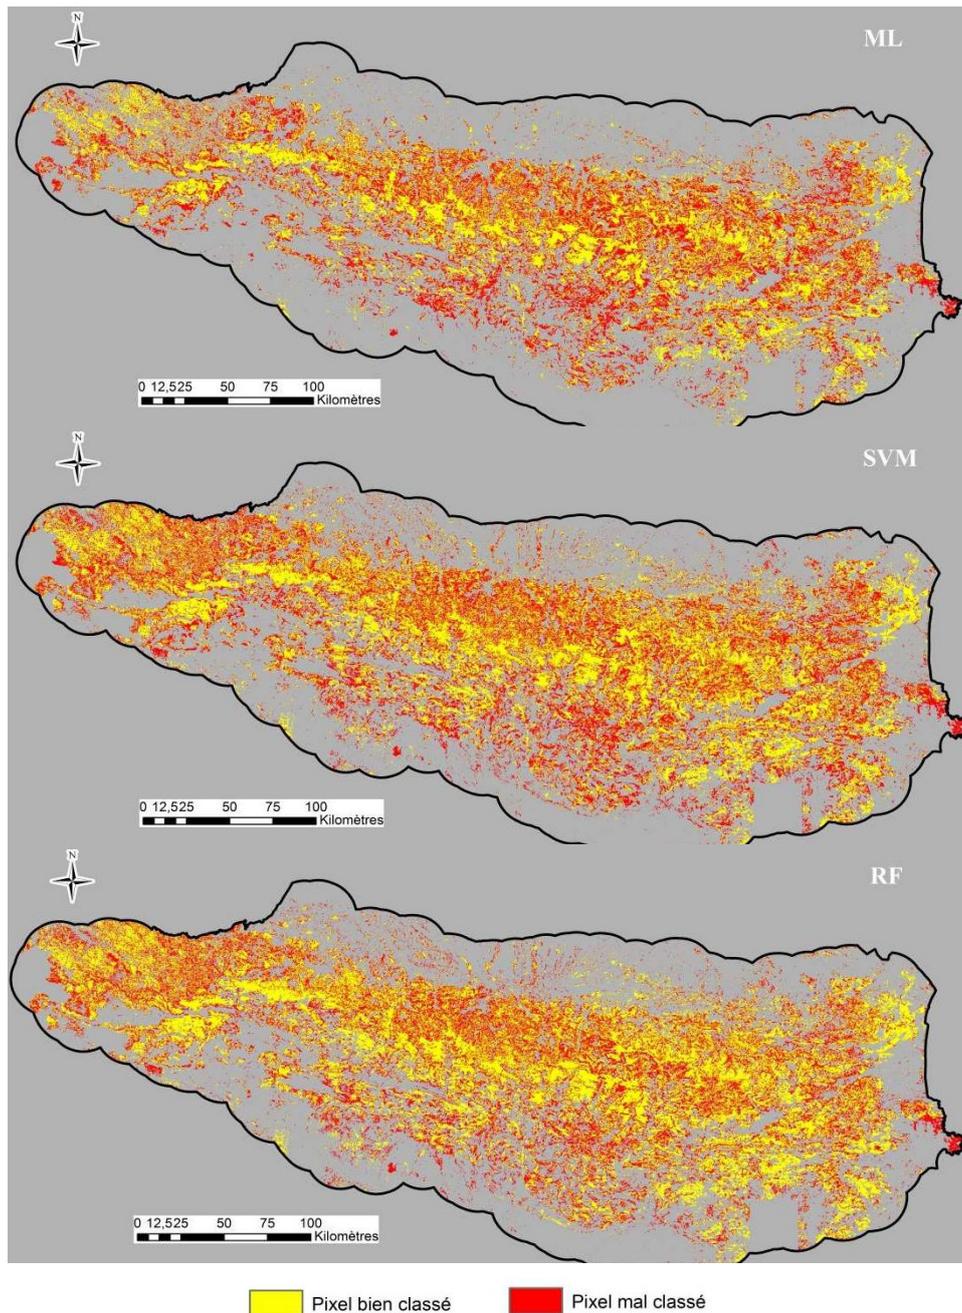


Figure 57 : Cartes des pixels bien et mal classés avec les algorithmes ML, SVM et RF pour la série 2000-2002 - procédures appliquées en configurations optimales.

Indicateur de fréquence de bon classement

Le calcul de la fréquence permet d'ajouter une dimension temporelle à la première analyse spatiale des proportions de pixels bien classés. Ici, la proportion de pixels pour chaque valeur de fréquence de bon classement a été calculée (tableau 32 et figure 58). Ces valeurs varient de 13 (pixel toujours classé comme la référence) à 0 (pixel jamais classé comme la référence), les valeurs intermédiaires indiquent le nombre de classification (série 3 ans) où un pixel a été classé comme la référence.

Pour les trois algorithmes de classification utilisés, on observe la même répartition des pixels :

- un pic pour la valeur de fréquence 13, correspondant aux pixels toujours classés comme la référence,
- un second pic, plus faible que le premier, pour la valeur de fréquence 0, correspondant aux pixels jamais classés comme la référence,
- des pourcentages similaires pour les valeurs de fréquence intermédiaires, de 1 à 12, correspondant aux pixels classés comme la référence de 1 à 12 années sur 13.

Tableau 32 : Proportion de pixels classés correspondant à chaque valeur de fréquence pour la période 2000-2014 et pour chaque algorithme de classification.

Proportion de pixels classés (%)			
Valeur de fréquence	ML	SVM	RF
13	25%	31%	49%
12	6%	7%	4%
11	5%	5%	3%
10	5%	5%	2%
9	4%	4%	2%
8	4%	4%	2%
7	4%	3%	2%
6	3%	3%	2%
5	4%	3%	2%
4	4%	3%	2%
3	4%	4%	2%
2	5%	4%	2%
1	6%	5%	3%
0	23%	19%	25%

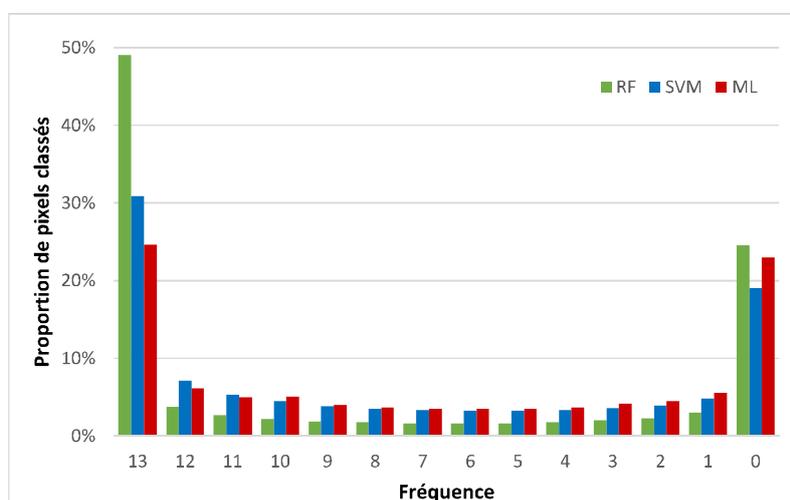


Figure 58 : Proportion de pixels classés correspondant à chaque valeur de fréquence pour la période 2000-2014 et pour chaque méthode de classification.

Cependant si la répartition est similaire pour les trois algorithmes, il existe des variations importantes. Pour le premier pic, fréquence de 13, on observe une différence importante entre d'une part ML et SVM avec respectivement 25 et 31% de pixels toujours bien classés, et d'autre part RF, qui présente 49% de pixels bien classés 13 fois.

Pour le pic à la fréquence 0, les valeurs sont assez proches pour les trois méthodes et respectivement égales à 23, 19 et 25% pour ML, SVM et RF. Pour les valeurs intermédiaires, fréquence de 12 à 1, le

nombre de pixels toujours bien classés est réparti de façon homogène. Pour ML et SVM on observe en moyenne 4% des pixels pour chaque valeur de fréquence et pour RF 2% en moyenne. Pour ces valeurs intermédiaires, le cumul des pourcentages souligne la différence entre RF et les 2 autres algorithmes. En effet, le cumul des pixels avec des valeurs de fréquence de 1 et 12, est de 52 et 50%, pour SVM et ML, alors que pour RF, il n'est que de 26%. Ces valeurs de fréquence peuvent représenter des changements d'occupation du sol, cependant les surfaces concernées sont beaucoup trop importantes. Il s'agit donc principalement d'erreurs.

Alors que les précédents résultats ont surtout montré un écart entre, d'une part ML et d'autre part, les deux autres algorithmes, l'indicateur de fréquence met en avant la plus forte stabilité cartographique pour RF comparativement à ML et SVM.

Indicateur de variabilité

Pour les trois algorithmes, on observe une majorité de pixels qui sont affectés à une ou deux classes, sur l'ensemble des 13 classifications, puis une proportion de pixels qui décroît rapidement avec l'augmentation de la variabilité de classes (figure 59). Il y a peu de pixels affectés à plus de cinq classes sur l'ensemble des 13 classifications.

Cependant on peut souligner des différences de qualité de classification selon les algorithmes :

- pour RF, 60% des pixels sont affectés à une seule classe, 24% à deux. Soit 84% des pixels qui ont une variabilité égale ou inférieure à 2.
- pour SVM, seuls 41% des pixels sont affectés à une seule classe. Les proportions pour deux et trois classes sont équivalentes, respectivement 22 et 19%. 63% des pixels ont une variabilité égale ou inférieure à 2.
- pour ML, la proportion de pixels de variabilité égale ou inférieure à 2 est similaire à celle de SVM (62%), mais les proportions pour une et deux classes sont différentes, respectivement 32 et 30%.

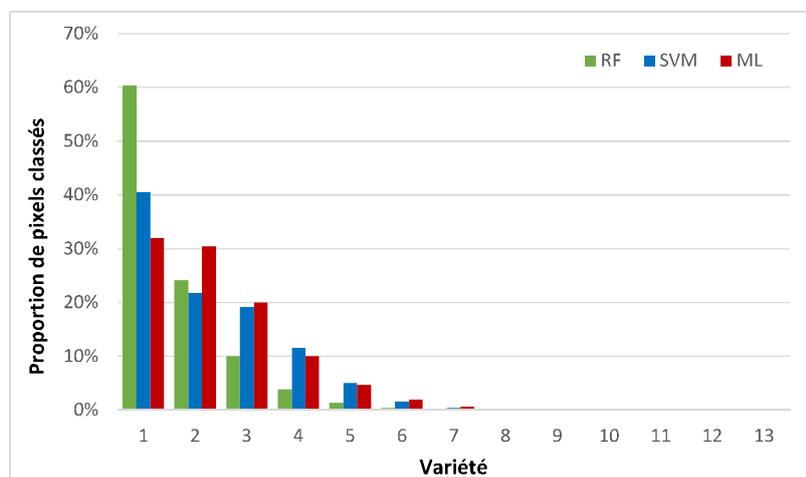


Figure 59 : Proportion de pixels selon nombre classes affectées pour la période 2000-2014 et pour chaque méthode de classification.

On considère la variabilité présentée ici comme un indicateur de qualité de la série de classification. Dans un paysage dominé par des formations végétales pérennes, on s'attend à ce que la variabilité soit en général de 1. Une variabilité supérieure à 1 peut représenter des changements d'occupation du sol mais aussi des erreurs. Cet indicateur n'utilise pas de référence et n'exprime pas de notion de bien ou de mal classé.

Comme précédemment, la stabilité met en évidence l'intérêt de RF, par rapport aux deux autres algorithmes, avec la proportion de pixels stables la plus élevée. Les proportions de pixels avec une variabilité de deux ou plus sont beaucoup trop importantes pour indiquer seulement du changement, il s'agit sans doute majoritairement d'erreurs de classification.

La représentation cartographique de l'indicateur de variabilité (figure 29) montre, d'une part les différences de qualité entre les trois algorithmes, d'autre part une répartition des pixels de variabilité élevée concentrée sur certaines zones (piémont, vallées) de manière similaire aux cartes des pixels bien et mal classés (figure 60).

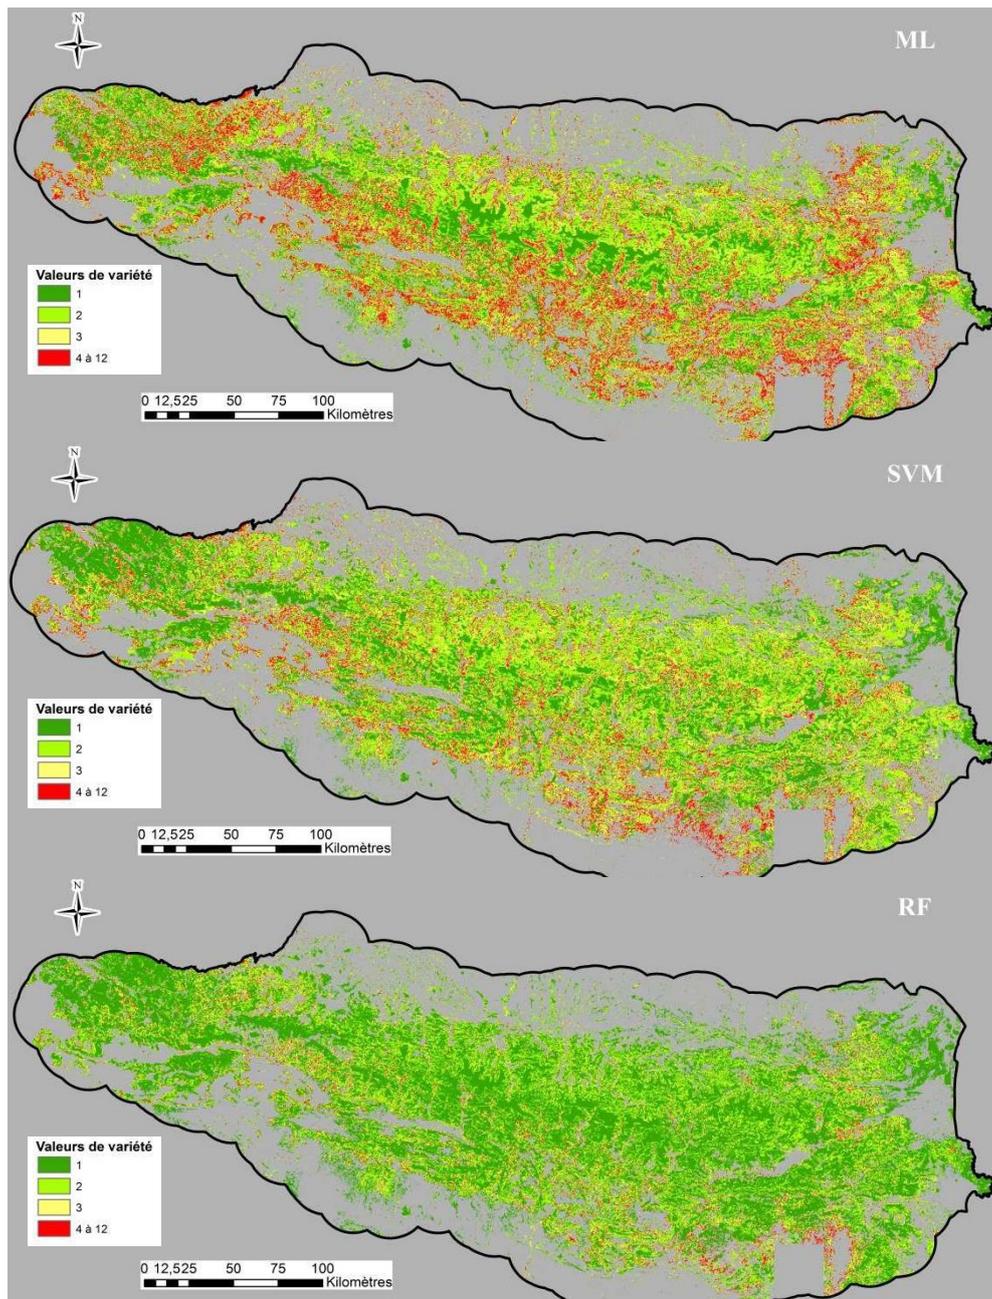


Figure 60 : Cartes du nombre de classes affectées pour la période 2000-2014 (variété) pour chaque algorithme de classification.

Combinaison fréquence/variabilité

Les deux indicateurs fréquence et variabilité sont deux indicateurs complémentaires de la stabilité temporelle des classifications réalisées sur les séries 3 ans de 2000 à 2014. Un mode de combinaison est proposé (tableau 16). Pour cela, les valeurs de fréquence sont regroupées en trois catégories : « toujours classé comme la référence » pour la valeur 13, « jamais classé comme la référence » pour la valeur 0, et « erreurs et changement » pour les valeurs de 1 à 12. Les valeurs de variabilité sont regroupées en deux catégories : « stable » pour la valeur 1, « erreurs et changement » pour les valeurs de 2 à 13.

La combinaison de ces deux indicateurs permet d'identifier 3 groupes de pixels : « stable et bien classé », toujours classés comme la référence, « stable et différent de la référence », jamais classés comme la référence mais toujours affecté à une même classe, les autres combinaisons sont soit impossibles soit correspondent à des situations instables, nommées « erreurs et changement » (tableau 33).

Tableau 33 : Combinaison des indicateurs fréquence et variabilité

			Variabilité												
			1	2	3	4	5	6	7	8	9	10	11	12	13
			Stable		Erreurs (et changement)										
Fréquence	13	Toujours classé comme la référence	Stable et bien classé	-											
	12	Erreurs (et changement)	-	Erreurs (et changement)											
	11														
	10														
	9														
	8														
	7														
	6														
	5														
	4														
	3														
	2														
	1														
	0	Jamais classé comme la référence	Stable et différent de la référence	Erreurs (et changement)											

L'intérêt de cette combinaison est de préciser le comportement des pixels qui ne sont jamais classés comme la référence (valeur de fréquence égale à 0). Si ces pixels sont affectés à différentes classes, ils sont alors considérés comme des erreurs (ou du changement). Toutefois, s'ils sont systématiquement affectés à une seule classe, alors on peut faire l'hypothèse qu'il ne s'agit pas d'erreur de classification mais plutôt la conséquence d'une erreur dans la donnée de référence. Ces pixels stables et différents de la référence représentent respectivement 6,7 et 15% des pixels pour les méthodes ML, SVM et RF.

Le cumul de pixels stables, c'est-à-dire toujours affectés à une même classe, apporte une interprétation complémentaire de la qualité des systèmes de classifications proposés. Les résultats obtenus mettent en avant une forte supériorité de la méthode RF quant à la stabilité temporelle des résultats de classification : 64% des pixels sont stables, contre respectivement 31 et 38% pour ML et SVM (figure 61). L'intérêt de RF, déjà mis en évidence précédemment, est ainsi confirmé.

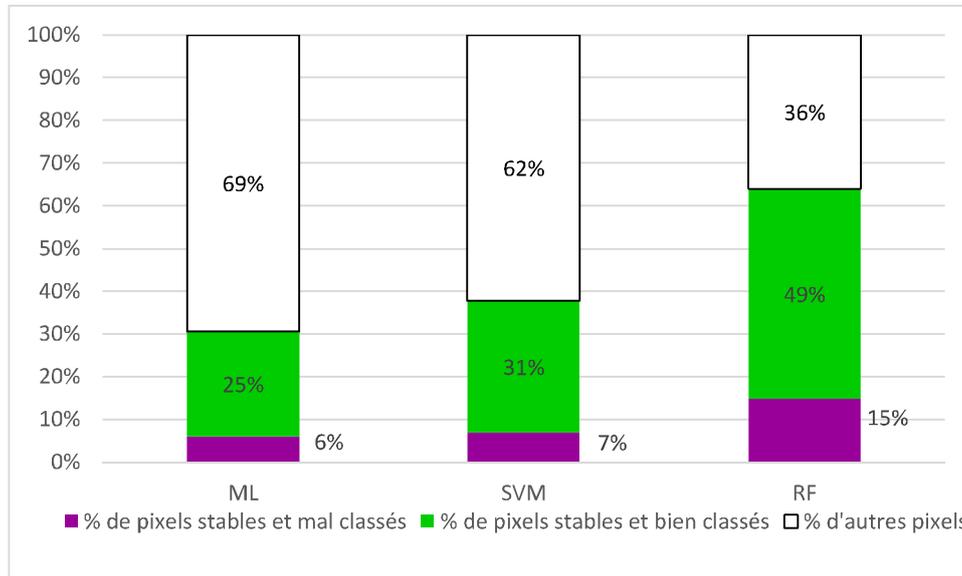


Figure 61 : Stabilité temporelle des résultats pour les 3 méthodes de classification : proportion de pixels toujours affectés à la même classe, en distinguant les classements identiques (pixels stables et bien classés) et différents de la référence (pixels stables et mal classés)

Sur l'extrait de carte ci-après (figure 62), on observe que les pixels stables et bien classés forment des continus sur des surfaces souvent assez étendues. Les pixels stables et mal classés sont aussi regroupés en patches et peu dispersés, ce qui va dans le sens d'une erreur dans les données de référence.

On remarque également sur cette illustration des alignements de pixels instables sur les limites séparant des formations végétales différentes. On peut faire plusieurs hypothèses sur l'origine de ces erreurs :

- elles sont liées à une zone de transition progressive entre 2 formations végétales qui n'est pas prise en compte par la délimitation des classes,
- elles peuvent être dues à la présence de pixels mixtes, dont la signature temporelle n'est pas reconnue par la classification,
- elles peuvent correspondre à des erreurs de calage des images qui créeraient des signatures aberrantes.

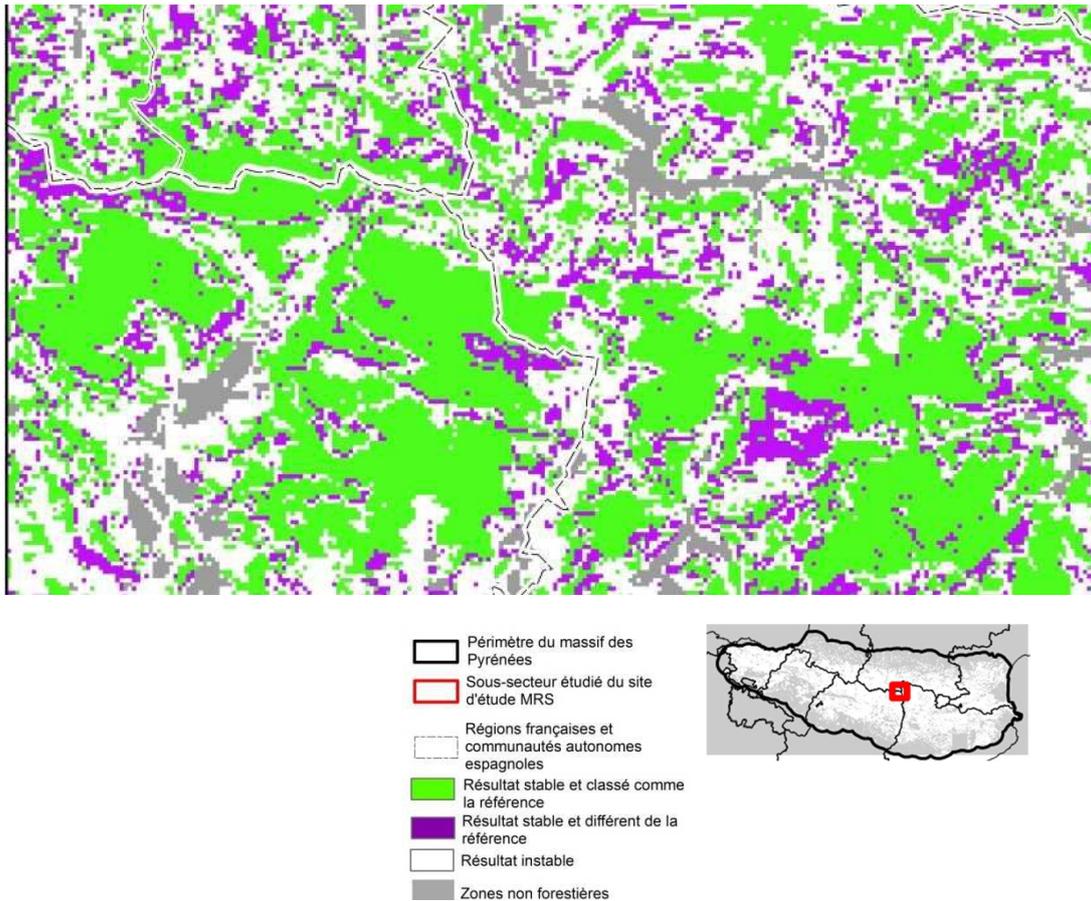


Figure 62 : Stabilité temporelle des résultats pour RF (classification en configuration optimale)

Influence de la surface des polygones de référence

Afin de mieux comprendre les différences de stabilité des résultats de classification, on a extrait, pour chaque pixel classé, la surface du polygone de la cartographie forestière utilisé pour définir la classe de référence de ce pixel. Ces surfaces ont ensuite été moyennées pour chaque valeur de fréquence.

On constate que les pixels toujours bien classés, correspondant à la valeur de fréquence 13, appartiennent à des polygones présentant la surface moyenne la plus élevée (figure 63). On observe ensuite que cette surface moyenne diminue en même temps que la fréquence. Ce phénomène est commun aux 3 algorithmes, mais plus ou moins marqué. Ainsi, c'est pour l'algorithme ML que la relation entre fréquence et surface semble la plus évidente. A l'inverse, RF est la méthode qui semble la moins sensible à la taille des polygones.

Une interprétation possible de ce résultat est qu'elle met en évidence une limite des images MODIS à 250 m de résolution spatiale lorsque le paysage à caractériser est trop morcelé ou hétérogène. L'hypothèse vraisemblable est que plus les polygones de référence ont une surface réduite, plus la proportion de pixels situés en limite de ces polygones est importante. On suppose que ces pixels sont fréquemment des pixels mixtes et sont généralement mal classés. Ainsi, plus le paysage est complexe, moins les pixels sont fréquemment bien classés.

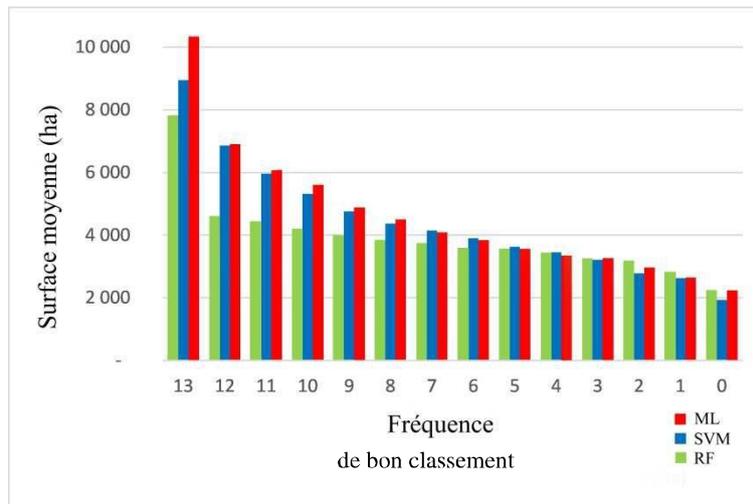


Figure 63 : Surface moyenne de polygone de la cartographie de référence (ha) en fonction de la valeur de fréquence de bon classement.

3.2.2 Analyse thématique des résultats

Si les valeurs de F-Score sont stables dans le temps, elles présentent toutefois une grande disparité selon les classes, variant de 25% à 81% (figure 64).

On observe que la hiérarchie du F-Score est similaire pour les 3 algorithmes. Il ne semble pas y avoir de méthode particulièrement plus adaptée qu'une autre pour la cartographie d'une formation végétale donnée. De façon cohérente avec l'ensemble des observations déjà réalisées, les résultats obtenus à partir de RF sont meilleurs que ceux de SVM et ML donne les moins bons résultats

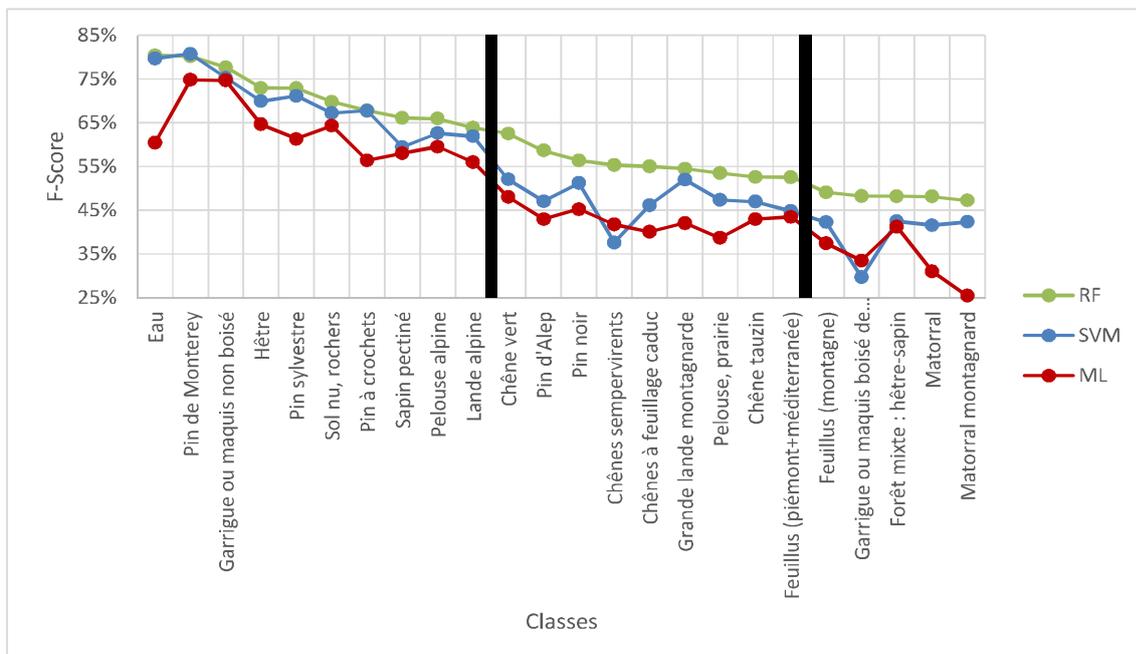


Figure 64 : Valeurs moyennes de F-Score par classe pour les 3 méthodes étudiées (moyenne des 13 classifications), triées par ordre décroissant des valeurs obtenues avec RF.

En observant l'organisation des valeurs de F-Score, on peut proposer des regroupements de classes dont les valeurs de F-Scores sont similaires (figures 64 et 65).

Pour le premier groupe de 10 classes, les valeurs de F-Score sont comprises entre 50% et 60% pour ML et entre environ 60% et 80% pour SVM et RF. Les résultats obtenus par ces deux derniers algorithmes sont très similaires et nettement supérieurs à ceux de ML. Les classes de ce groupe sont principalement des formations homogènes et/ou présentes sur de grandes surfaces.

Le groupe suivant présente une qualité de résultat nettement inférieure. Ici ce sont les résultats pour ML et SVM qui sont proches. Ils sont compris entre 43% et 52%. Pour RF les valeurs de F-Score sont systématiquement supérieures aux deux autres algorithmes et comprises entre 53 et 63%. Dans ce groupe on retrouve des formations qui ont souvent une organisation spatiale ou composition hétérogène.

Dans le dernier groupe, seul RF présente des valeurs supérieures à 47% (entre 47% et 49%), SVM a des valeurs proches de 42% et les valeurs sont nettement inférieures pour la méthode ML (entre 25% et 41%). Les classes de ce groupe sont principalement des formations mixtes, voire indifférenciées.

On note que la méthode SVM est moins performante que la méthode ML pour deux classes (figure 65) : le mélange de chênes sempervirents et la garrigue boisée.

Tableau 34 : Valeur moyenne par classe des indicateurs de précision (F-score, erreur d'omission et de commission) pour les 3 algorithmes (moyenne des 13 classifications).

Dénomination	RF	SVM	ML	RF	RF	SVM	SVM	ML	ML
	F-Score			omission	commission	omission	commission	omission	commission
Eau	80%	80%	60%	24%	15%	22%	18%	24%	50%
Pin de Monterey	80%	81%	75%	7%	30%	7%	29%	29%	21%
Garrigue ou maquis non boisé	78%	75%	75%	13%	30%	14%	33%	25%	25%
Hêtre	73%	70%	65%	31%	22%	35%	24%	42%	27%
Pin sylvestre	73%	71%	61%	31%	23%	33%	24%	47%	28%
Sol nu, rochers	70%	67%	64%	30%	31%	34%	31%	33%	38%
Pin à crochets	68%	68%	56%	24%	39%	24%	39%	48%	39%
Sapin pectiné	66%	59%	58%	34%	34%	36%	45%	47%	37%
Pelouse alpine	66%	63%	60%	42%	24%	46%	26%	43%	38%
Lande alpine	64%	62%	56%	30%	42%	33%	43%	37%	50%
Chêne vert	63%	52%	48%	41%	34%	52%	43%	57%	46%
Pin d'Alep	59%	47%	43%	40%	42%	49%	57%	64%	46%
Pin noir	56%	51%	45%	38%	49%	45%	52%	53%	57%
Chênes sempervirents	55%	38%	42%	45%	44%	61%	64%	58%	58%
Chênes à feuillage caduc	55%	46%	40%	48%	42%	50%	57%	60%	60%
Grande lande montagnarde	54%	52%	42%	43%	48%	48%	48%	48%	65%
Pelouse, prairie	53%	47%	39%	49%	43%	57%	48%	44%	70%
Chêne tauzin	53%	47%	43%	34%	56%	41%	61%	53%	60%
Feuillus (piémont+méditerranée)	53%	45%	43%	51%	43%	57%	53%	57%	56%
Feuillus (montagne)	49%	42%	37%	53%	49%	58%	58%	64%	61%
Garrigue ou maquis boisé de chêne vert	48%	30%	33%	59%	42%	72%	68%	67%	66%
Forêt mixte : hêtre-sapin	48%	42%	41%	33%	62%	44%	66%	59%	59%
Matorral	48%	42%	31%	51%	53%	56%	61%	56%	76%
Matorral montagnard	47%	42%	25%	50%	56%	58%	58%	79%	69%

L'examen des valeurs moyennes par classe des erreurs d'omission et de commission confirme les observations réalisées avec le F-Score (figure 65). L'algorithme RF produit systématiquement les meilleurs résultats pour toutes les classes. ML, à l'opposé, présente des résultats qui sont systématiquement les moins bons. SVM est similaire à RF pour les 10 classes du premier groupe, alors que ses résultats sont équivalents à ML pour les autres classes.

Au-delà de l'évaluation des indicateurs de précision, la matrice de confusion permet de comprendre un certain nombre d'erreurs et de limites. En effet la présentation précédente par classe impose de travailler en pourcentage, puisque les indicateurs de précision ne rendent pas compte de l'impact de la qualité de chaque classe sur le résultat global. En présentant les surfaces (en ha) obtenues par le croisement de la référence avec le résultat de la classification, on a une vision de l'effet de chaque

classe sur le résultat global. On va ainsi se rendre compte que certaines classes, qui ont des erreurs d'omission et de commission relativement faibles, mais qui représentent une grande superficie, peuvent avoir un impact important sur les surfaces mal classées. Les résultats sont interprétés à partir des 13 classifications produites avec l'algorithme RF pour les séries 3 ans de 2000 à 2014. La matrice présentée est la moyenne des 13 matrices calculées (figure 66).

Tableau 35 : Matrice de confusion moyenne des 13 classifications produites avec l'algorithme RF pour les séries 3 ans de 2000 à 2014 (valeurs en milliers d'hectares). Valeurs en rouge : surfaces supérieures à 8 000 ha. Les couleurs des groupes de classes sont reprises de la figure précédente.

Référence (lignes)	Classification (colonnes)																				Total référence (x10 ³ ha)				
	Chênes à feuillage caduc	Feuillus (piémont+méditerranée)	Feuillus (montagne)	Hêtre	Chêne tauzin	Chêne vert	Chênes sempervirents	Pin à crochets	Pin d'Alep	Pin noir	Pin sylvestre	Pin de Monterey	Sapin pectiné	Forêt mixte : hêtre-sapin	Garrigue ou maquis boisé	Garrigue ou maquis non boisé	Matorral	Matorral montagnard	Pelouse, prairie	Grande lande montagnarde		Lande alpine	Pelouse alpine	Sol nu, rochers	Eau
Chênes à feuillage caduc	55	12	8	4	4	2	1	0	0	1	2	3	0	0	0	1	2	2	2	4	0	0	0	0	105
Feuillus (piémont+méditerranée)	19	67	7	9	3	7	3	0	0	1	0	7	0	1	1	2	2	0	2	7	0	0	0	0	137
Feuillus (montagne)	6	8	61	14	2	4	1	2	0	1	4	0	2	5	1	0	0	4	1	8	6	1	0	0	130
Hêtre	1	17	21	211	4	0	0	0	-	0	3	3	1	21	0	0	1	1	6	8	6	1	0	0	306
Chêne tauzin	1	0	0	2	37	1	2	0	0	2	3	1	0	0	0	0	3	2	2	0	0	0	-	0	57
Chêne vert	2	2	1	0	2	100	8	0	3	8	8	3	0	0	12	3	8	7	0	0	0	0	0	0	168
Chênes sempervirents	1	1	0	0	5	6	38	0	1	4	3	0	0	0	1	3	4	2	0	0	-	-	0	0	70
Pin à crochets	0	0	1	0	0	0	0	91	-	0	7	-	3	1	0	-	-	2	0	0	4	9	2	0	120
Pin d'Alep	0	0	0	0	0	2	1	0	22	3	0	2	0	-	0	3	3	0	0	0	-	-	0	0	37
Pin noir	1	1	0	1	3	3	2	0	4	58	8	5	0	0	2	0	3	1	0	0	-	-	0	0	93
Pin sylvestre	2	1	4	3	5	8	3	18	0	21	207	1	2	4	1	0	2	13	1	0	1	1	0	0	300
Pin de Monterey	1	2	0	0	1	0	0	-	0	0	0	95	0	-	0	0	0	0	2	1	-	-	0	0	102
Sapin pectiné	0	0	1	2	0	0	-	2	-	0	1	0	37	11	-	-	0	0	0	1	0	-	0	-	56
Forêt mixte : hêtre-sapin	0	0	2	5	0	0	0	0	-	0	0	0	4	30	0	0	-	0	0	0	2	0	-	0	44
Garrigue ou maquis boisé de chêne vert	0	0	0	0	5	11	4	-	1	5	3	0	0	0	37	11	4	5	0	0	0	0	0	0	89
Garrigue ou maquis non boisé	1	0	0	-	0	1	1	-	1	1	0	0	0	-	4	67	0	0	0	1	0	-	0	0	77
Matorral	1	2	0	2	4	2	1	0	3	4	2	4	0	0	1	1	40	7	3	5	0	0	0	1	83
Matorral montagnard	1	0	1	2	3	2	1	6	0	3	11	0	0	0	2	0	6	56	3	1	3	8	2	0	111
Pelouse, prairie	2	1	2	5	3	1	0	0	0	1	3	8	0	0	0	1	1	8	45	7	1	0	0	0	89
Grande lande montagnarde	3	3	6	7	2	0	0	0	0	0	1	2	1	1	0	2	1	1	5	54	4	0	0	0	94
Lande alpine	0	0	1	2	0	0	-	7	-	0	0	0	3	3	0	0	-	2	0	4	105	14	8	0	149
Pelouse alpine	0	-	1	1	0	0	0	16	0	0	1	-	2	2	0	-	0	10	1	2	38	157	39	0	270
Sol nu, rochers	0	0	0	1	1	0	0	7	0	1	1	1	0	0	0	3	3	4	1	9	16	117	0	0	167
Eau	0	0	0	0	0	0	0	0	1	0	0	0	0	0	0	1	2	0	0	0	1	0	1	24	32
Total classification (x10 ³ ha)	95	117	119	272	85	151	68	150	38	113	268	135	55	79	64	96	85	126	79	103	180	208	169	28	2 884

Les confusions les plus importantes visibles sur la matrice ne sont pas réparties de façon homogène sur l'ensemble des classes, nous avons identifié plusieurs ensemble de classes dont les confusions sont importantes en termes de surface (encadrées sur la figure 66).

On observe un premier ensemble de confusions entre des classes de feuillus caducs : chênes à feuillage caduc, feuillus (piémont, méditerranée et montagne) et hêtre. Les confusions entre ces classes couvrent 126 600 ha, soit 4,4% de la surface classée. La classe de hêtre qui est relativement bien classée (erreur d'omission et de commission respectivement de 31 et 22%) mais comme elle couvre une surface très importante elle participe à presque la moitié de ces confusions (66 300 ha, soit 2,3% de la surface classée totale). La phénologie de ces classes est proche et explique ces confusions. De plus, les 2 classes de feuillus sont des formations composées d'essences non différenciées qui peuvent contenir dans certains cas des chênes et des hêtres. Sur la carte de la figure 67, on s'aperçoit que ces confusions sont souvent localisées le long des limites des polygones de la carte forestière, sur des secteurs de transitions où l'on trouve des mélanges d'essences.

Les classes de lande alpine, pelouse et sol nu forment un deuxième ensemble de confusions et couvrent des surfaces importantes, presque 590 000 ha, soit environ 20% de la superficie classée. Les confusions entre la lande alpine, la pelouse et le sol nu couvrent des surfaces importantes, alors que ces trois classes ont de très bons critères de qualité. Les principales confusions ont lieu entre ces trois classes. Elles couvrent environ 124 000 ha (4,3% de la superficie classée) à rapprocher de la superficie bien classée : 380000 ha (13,2% de la superficie classée). Les autres confusions significatives concernent la classe de pelouse alpine avec les classes de pin à crochet et de matorral montagnard. Il s'agit aussi bien d'erreur d'omission (26 000 ha pour ces deux classes) que de commission (17 000 ha pour les deux classes). Une explication possible de ces erreurs est liée à la référence utilisée pour cartographier ces trois classes. Elles ne sont pas toujours explicitement cartographiées dans les inventaires forestiers, landes et pelouses sont souvent réunies dans une seule classe et le sol nu est plutôt identifié par défaut en l'absence d'autres informations ou inclus dans des classes de pelouse. Ces imprécisions dans les documents originaux ont pu être sources d'erreur lors du travail de synthèse pour la réalisation de la carte forestière. D'autre part, les classes de pin à crochet, lande, pelouse et sol nu forment souvent des mélanges et des gradients qui ne sont pas représentés par les limites des polygones des cartes forestières.

Un troisième ensemble de confusions est observé entre les classes du hêtre, du sapin pectiné et de la forêt mixte hêtre-sapin. Pour ce groupe, les confusions sont surtout des erreurs de commission de la hêtraie-sapinière. Elles s'élèvent à 62,5% et correspondent à une surface de 31 900 ha, soit 1,1% de la surface classée totale. La carte de la figure 67 montre que ces confusions sont généralement présentes sous deux formes d'organisation spatiale : soit des groupes de pixels correspondant à des polygones ou des parties de polygones de la carte forestière, soit des alignements de pixels le long des limites de ces polygones.

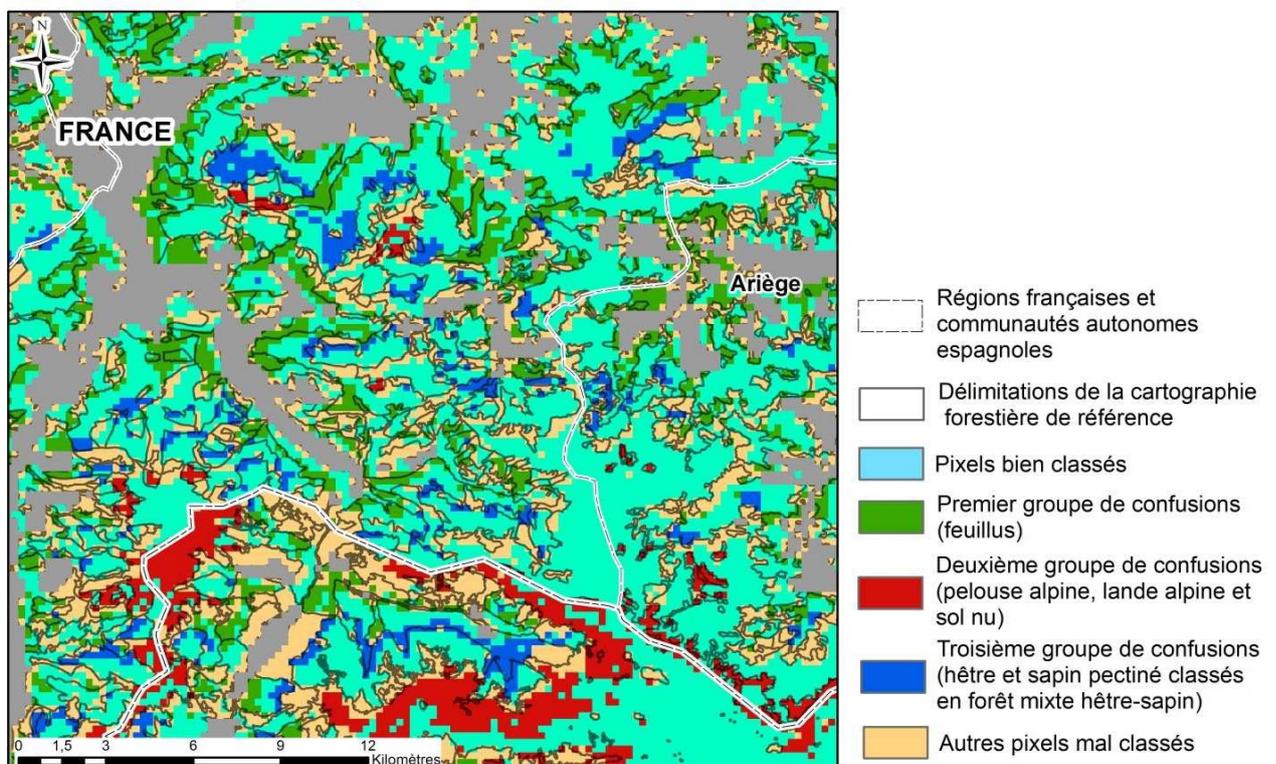


Figure 65 : Extrait des principales confusions de la classification 2000-2003 (RF). Les limites en noir sont celles de la cartographie forestière.

D'autres confusions, moins importantes en termes de superficie, existent. On les observe entre le pin sylvestre et le pin noir, le pin à crochet mais aussi le chêne vert. On les observe également entre le chêne vert, la garrigue ou maquis boisé de chêne vert et la garrigue ou maquis non boisé qui forment aussi un gradient de densité de végétation.

4 Discussion - conclusion

4.1 Bilan sur l'amélioration des procédures de classification

Les travaux réalisés ont souligné l'importance d'une réflexion préalable sur la définition d'une procédure de classification adaptée au besoin cartographique et aux caractéristiques des données à traiter. Ils ont particulièrement mis en avant 2 effets majeurs sur la qualité des résultats liés à l'organisation des séries temporelles : l'apport de la temporalité et l'apport de la radiométrie.

L'apport de la temporalité s'est caractérisé par une amélioration observée :

- pour l'utilisation de séries temporelles au lieu de séries d'images multidates,
- pour l'utilisation de série de plusieurs années de durée.

Il est ainsi nécessaire de prendre en compte le plus d'informations possible concernant le cycle phénologique des essences, mais aussi concernant plusieurs cycles annuels successifs. Ces conclusions viennent confirmer celles de nombreuses études menées sur le sujet (Goetz et al., 1999 ; Heiskanen et Kivinen, 2008 ; Hill et al., 2010 ; Knight et al., 2006 ; Loveland et al., 2000 ; Reed et al., 1994). Cet apport est d'autant plus important lorsqu'on choisit, comme dans le cas de notre étude, d'exploiter un faible nombre de bandes spectrales (Carrão et al., 2008).

L'intérêt d'utiliser des séries temporelles de plusieurs années est moins étudié dans la littérature. Il a néanmoins déjà été démontré que de telles séries permettaient d'atteindre une précision suffisante pour caractériser des gradients de végétation à partir d'images MODIS (Ali et al., 2013). D'après cette étude, l'exploitation de plusieurs cycles annuels de végétation successifs permet d'obtenir des informations sur les fluctuations des caractéristiques de croissance des essences d'une année sur l'autre. Nos résultats sont cohérents avec ces conclusions. La comparaison réalisée entre ML, SVM et RF nous permet d'enrichir les conclusions trouvées dans la littérature en précisant que l'apport de la temporalité n'est pas dépendant du choix de l'algorithme.

L'étude a également mis en évidence des résultats nettement meilleurs pour les données radiométriques que pour les indices de végétation. Ce constat n'est pas cohérent avec la grande majorité des études produites sur ce sujet, qui concluent qu'il est préférable d'utiliser le NDVI ou l'EVI plutôt que des réflectances (Gao et Mas, 2008 ; Price et al., 2002). Toutefois, peu de ces travaux de cartographie de la végétation sont basés sur de véritables séries temporelles constituées de réflectances. Dans l'étude de (Price et al., 2002), ce travail a été réalisé pour une série de 5 dates et une amélioration a été observée en augmentant le nombre de bandes spectrales différentes de la série. La bande spectrale NIR a ainsi été identifiée comme la plus informative pour distinguer des essences, ce qui confirme son apport et va dans le sens de nos observations.

L'autre effet majeur sur la qualité de classification mis en évidence par notre étude est celui du choix de l'algorithme. Les travaux menés permettent de conclure que RF est systématiquement préférable aux deux autres algorithmes étudiés pour obtenir la meilleure qualité de classification. Ils soulignent également que le maximum de vraisemblance donne toujours de moins bons résultats que les algorithmes non paramétriques. De nombreux cas d'études mettent en évidence l'obtention de

meilleurs résultats à partir d'algorithmes non paramétriques qu'à partir du maximum de vraisemblance (Foody, 2002 ; Lu et Weng, 2007 ; Paola et Schowengerdt, 1995). Lorsqu'une étude met en avant de meilleurs résultats pour ML que pour RF, c'est au sujet de sa faible sensibilité aux jeux d'entraînement de faible taux d'échantillonnage (Li et al., 2014). Pour ce qui concerne la comparaison entre RF et SVM, plusieurs études concluent à un niveau de performance similaire des deux algorithmes (Abdel-Rahman et al., 2014 ; Immitzer et al., 2012). Nos résultats ont mis en avant une qualité de classification supérieure pour RF ainsi que certaines limites de SVM.

La tendance à l'overfitting de SVM avec l'augmentation du taux d'échantillonnage du jeu d'entraînement, ainsi que l'existence d'une taille optimale de ce jeu d'entraînement propre à chaque algorithme ont déjà été établies (Foody et Mathur, 2006). Nos résultats sont cohérents avec ces conclusions. En revanche, ils semblent infirmer le besoin exclusif en pixels mixtes de SVM pour fonctionner de façon optimale (Foody et Mathur, 2004 ; Foody et Mathur, 2006). D'après nos constatations, cet algorithme n'a pas de comportement spécifique par rapport à la teneur en pixels mixtes du jeu d'entraînement et les pixels « purs » sont également utiles à son fonctionnement optimal.

La supériorité de RF sur les 2 autres algorithmes de classification a été confirmée par l'ensemble des séries de résultats de l'étude. Si on cumule l'apport de l'ensemble des caractéristiques optimales adoptées successivement dans le cadre de cette étude, l'usage de RF permet un gain maximal d'indice de Kappa de 0,32, contre 0,25 pour SVM et 0,22 pour ML. Ces apports sont par ailleurs nettement supérieurs à celui du recours à la stratification, testé dans le chapitre précédent, qui n'est que de 0,12.

4.2 Bilan sur l'analyse temporelle et spatiale des résultats

La supériorité de RF ne se traduit pas qu'en termes de gain de précision exprimé par l'indice de Kappa, mais également par une stabilité spatiale et temporelle remarquable de la qualité de ses résultats.

Sur une période de 13 années successives, la classification par RF permet d'obtenir deux fois plus de pixels bien classés 13 fois de suite que ML ou SVM. Cet écart est important sur le plan quantitatif : 49% des pixels à classer sont concernés dans le cas de RF contre 31% pour SVM et 25% pour ML. Ainsi, pour les mêmes données d'entrée, RF présente une stabilité temporelle nettement supérieure à celle de ML, mais aussi à celle d'un autre algorithme non paramétrique basé sur des règles de décision différentes. Aucune référence trouvée dans la littérature n'a permis de conforter ou de contredire cette constatation.

L'analyse temporelle permet de faire une autre constatation importante : quel que soit l'algorithme concerné, les classifications présentent une proportion notable de pixels stables mais classés différemment de la référence. Cette proportion reste du même ordre de grandeur pour ML et SVM (respectivement 6 et 7%) et est multipliée par deux dans le cas de RF (15%), l'algorithme le plus fiable. Ces résultats, ainsi que les caractéristiques spatiales de ces pixels (regroupés en patches), mettent en évidence des erreurs dans la cartographie forestière de référence.

4.3 Bilan sur l'interprétation thématique des résultats

L'interprétation thématique des résultats a permis d'observer que la qualité de classification est très variable selon les classes et que les mieux classées sont les plus homogènes sur le plan radiométrique et les plus étendues. La faible précision de certaines classes (toutes des formations mixtes et indifférenciées) peut conduire à remettre en question la nomenclature qui a été appliquée.

Les confusions obtenues présentent une logique thématique : elles sont systématiquement observées entre des classes ayant des essences en commun et peuvent donc correspondre à une situation réelle de mélange, comme dans le cas de la forêt mixte hêtre-sapin. On peut donc en conclure que ces imprécisions ne remettent pas en question la définition des classes, correspondant aux 22 formations végétales.

Il existe néanmoins des voies d'amélioration. Une première perspective serait de reprendre le jeu d'entraînement et de le baser uniquement sur les pixels qu'on a identifiés comme stables et bien classés, afin d'obtenir une meilleure représentativité pour chaque classe. Une autre possibilité consisterait à distinguer des sous-classes pouvant préciser la définition des formations mixtes et indifférenciées, par exemple en séparant le matorral boisé du matorral non boisé. La dernière voie d'amélioration consiste à travailler à une plus haute résolution spatiale.

Ces résultats montrent que, quelle que soit la procédure de classification, une interprétation de la qualité des résultats ne peut être réalisée sans une réflexion par rapport à la qualité des données de référence et vont dans le sens, comme pour les analyses précédentes, d'une analyse critique de la cartographie forestière employée.

4.4 Analyse critique de la carte forestière de référence

La carte forestière de référence utilisée pour les travaux de classification constitue la meilleure source d'information disponible relative à la végétation du site d'étude MRS. Elle présente notamment l'avantage d'être exhaustive pour l'ensemble du territoire étudié. Cette qualité a permis d'exploiter des taux d'échantillonnage importants pour les jeux d'entraînement utilisés et d'identifier leur valeur optimale pour les trois algorithmes. Aucune configuration optimale n'aurait pu être garantie à partir de données moins complètes, telles que les placettes d'inventaire de l'IFN, dont l'effectif représente moins de 1% de la totalité des pixels à classer du site d'étude.

Comme toute cartographie d'une telle étendue, basée sur des inventaires de terrain ponctuels et sur de la photointerprétation, elle ne peut être exempte d'imprécisions générant des erreurs de classification. Ces imprécisions peuvent être liées :

- à l'attribution des polygones,
- à l'existence d'hétérogénéités intra- polygone,
- à l'existence de gradients de végétation,
- aux changements s'étant produits entre la date de création de la cartographie (antérieure à 2005) et 2014,
- aux critères utilisés pour individualiser des formations mixtes telles que la forêt mixte hêtre-sapin.

Des erreurs liées à de mauvaises attributions de polygones ont été mises en évidence par l'analyse de la stabilité temporelle : elles correspondent aux pixels stables et classés différemment de la référence. Les hétérogénéités intra-polygone et les zones de gradient de végétation ont également été détectées. Elles se traduisent par des confusions, mises en évidence par les matrices. Trois grands types de confusions ont ainsi été identifiés à partir de la meilleure classification obtenue par RF et ont également été caractérisées sur le plan spatial. La carte de ces confusions permet de déduire qu'elles sont à la fois dues à des gradients et à des hétérogénéités locales. Les présents travaux n'ont pas permis de mettre en évidence, parmi le reste des pixels mal classés, les erreurs liées à des changements d'occupation des sols. Une telle analyse pourrait être mise en œuvre à partir d'informations complémentaires sur le site d'étude et constitue une perspective d'approfondissement de ces travaux.

4.5 Perspectives d'approfondissement

L'interprétation des résultats obtenus a permis d'identifier des caractéristiques des procédures de classification ayant une forte influence sur leur qualité. La précision globale et la précision thématique atteintes à l'issue de cette étude sont ainsi satisfaisantes, grâce à la définition d'une configuration optimale de ces procédures. L'étude a également permis de mettre en évidence plusieurs types d'erreurs de classification liées à des imprécisions dans les données de référence. Les procédures de classification optimales identifiées restent ainsi perfectibles, notamment du fait des pixels mal classés liés à ces imprécisions.

Les données image ayant servi de base à la construction des séries temporelles étudiées sont à moyenne résolution spatiale. Elles sont par conséquent constituées d'une forte proportion de pixels mixtes. Sur le site d'étude MRS, on estime cette proportion à environ 40% des 540 467 pixels à classer. La présente étude a permis de démontrer que la quantité de pixels mixtes composant le jeu d'entraînement n'avait pas d'incidence sur les résultats de classification. L'analyse temporelle et spatiale des résultats a par contre permis de déterminer que les pixels instables sur le plan temporel étaient particulièrement concentrés sur les limites entre classes, correspondant à la localisation des pixels mixtes. Ainsi, ces derniers jouent un rôle dans la perte de précision des résultats de classification.

Ces conclusions ont mis en avant la nécessité d'approfondir la présente étude par l'application d'une démarche similaire à une série temporelle à haute résolution spatiale. Le changement de résolution spatiale peut permettre de diminuer la proportion de pixels mixtes composant les pixels à classer. Il est souhaitable de vérifier si ce changement permet d'améliorer la qualité des résultats de classification. Une telle analyse peut également fournir un recul critique sur les erreurs liées aux critères d'individualisation des formations mixtes dans les données de référence. Pour les formations en mélange telles que la forêt mixte hêtre-sapin, il est ainsi intéressant de vérifier si le changement de résolution spatiale améliore leur distinction ou s'il mène à identifier une mosaïque de formations pures telles que le hêtre ou le sapin pectiné.

L'apport d'un tel changement de résolution spatiale a par conséquent été étudié. Les résultats obtenus sont présentés en chapitre V.

Cette étude fait l'objet d'une publication qu'il est prévu de soumettre avant fin 2016 :

Denux, J.P., **Cano, E.**, Hubert-Moy, L., et Chéret, V., Comparison of maximum likelihood, support vector machine and random forest for forest types mapping with MODIS time series.

Chapitre V: Apport d'une série temporelle à haute résolution spatiale

L'apport de la configuration optimale d'une procédure de classification a été évalué dans le chapitre précédent. L'influence de l'organisation de la série temporelle sur la qualité des résultats a ainsi été établie. Parmi les facteurs limitant la précision thématique, le nombre de pixels mixtes dans les images a été mis en évidence. La série temporelle traitée au chapitre précédent, de moyenne résolution spatiale, favorise la présence d'une forte proportion de pixels mixtes dans la population de pixels à classer.

Ce chapitre porte sur l'étude de l'apport du changement de résolution spatiale de la série temporelle traitée pour améliorer la précision de classification. Plus précisément, il s'agit d'évaluer dans quelle mesure une série temporelle d'images à haute résolution spatiale permet, par la diminution de la quantité de pixels mixtes à classer, d'atteindre de meilleurs résultats. A cette fin, une série composée d'images DEIMOS, de 22 m de résolution spatiale, a été utilisée.

Les deux meilleurs algorithmes de classification mis en évidence dans le chapitre IV, SVM et RF, ont été retenus pour classer les images DEIMOS.

L'étude précédente a mis en évidence des confusions notables entre le sapin pectiné, le hêtre et la forêt mixte d'une part, et la lande alpine, la pelouse alpine et le sol nu d'autre part. On a souhaité s'intéresser spécifiquement à ces formations. Le site d'étude traité (site d'étude HRS), est localisé dans le versant français du massif montagneux des Pyrénées, au sein duquel ces formations sont particulièrement présentes et étagées selon l'altitude (chapitre II, partie 1.2.2).

Afin de caractériser l'évolution des résultats générée par le changement de résolution spatiale, une démarche générale identique à celle de l'étude précédente a été appliquée. Dans un premier temps, on fait varier différentes modalités des données d'entrée, c'est-à-dire le taux d'échantillonnage du jeu d'entraînement, la composition de la série d'images DEIMOS et l'ajout de données ancillaires. Puis, les résultats obtenus pour chacune de ces modalités et pour chaque algorithme sont analysés. La configuration optimale spécifique à chaque algorithme est alors identifiée de la même manière que précédemment.

1 Méthodes

1.1 Procédures de classification

1.1.1 Site d'étude et nomenclature

Le site d'étude HRS, localisé principalement sur le versant français des Pyrénées, correspond à une surface totale d'environ 145 000 ha. La nomenclature définie pour les classifications se compose de 6 classes (tableau 34). Elles se répartissent selon le gradient d'altitude, avec des formations forestières sur les étages les plus bas puis un gradient de landes et pelouses, jusqu'au sol nu.

Tableau 36: nomenclature retenue pour le site d'étude HRS.

Classes
Hêtre
Forêt mixte : hêtre-sapin
Sapin pectiné
Lande alpine
Pelouse alpine
Sol nu, rochers

Les deux essences forestières majoritairement présentes sur le site sont le hêtre et le sapin. Les peuplements de hêtre et de sapin sont définis comme purs par l'IFN lorsqu'une essence domine le peuplement et y est présente sur plus de 50% de la surface alors qu'aucune autre essence ne représente plus de 15% (Morneau et al., 2016). La transition entre ces deux formations est marquée par le développement d'une forêt mixte à hêtre et sapin (hêtraie-sapinière). Les milieux ouverts d'altitude (pelouse et lande alpines) succèdent aux peuplements de sapin, et correspondent aux dernières formations végétales d'altitude.

La surface à traiter correspondant à ces 6 classes est de 71 425 ha, soit 1 473 480 pixels.

1.1.2 Paramétrage des algorithmes de classification

A l'instar de ce qui a été effectué dans le cadre de l'étude précédente, les paramètres des algorithmes ont été adaptés au jeu de données.

Pour SVM, les réglages sont similaires à ceux du chapitre précédent :

- la fonction de base radiale (« Gaussian radial basis function ») a été utilisée,
- les paramètres C et γ ont été optimisés pour chaque classification.

Pour l'algorithme RF, les paramètres ont été optimisés selon la démarche décrite dans le chapitre précédent.

1.1.3 Jeu d'entraînement - Variation du taux d'échantillonnage

Le jeu d'entraînement a été constitué à partir de pixels entièrement inclus dans les délimitations des 6 classes de la cartographie forestière de référence, ce qui exclut les pixels mixtes. L'effectif total de cette population de pixels de référence, susceptibles d'être utilisés comme pixels d'entraînement, est de 1 318 033 pixels (soit 63890 ha).

A la résolution spatiale des images DEIMOS (22 m), la notion de pixel mixte telle que définie pour la résolution spatiale MODIS n'a plus vraiment de sens par rapport à des limites de classe issues de cartes à l'échelle du 1/50 000. De ce fait, l'influence de la variation du taux de classe majoritaire n'a pas été étudiée.

On a, par contre, souhaité analyser l'effet du taux d'échantillonnage selon la méthode appliquée sur les images MODIS. Nous avons fait varier le taux d'échantillonnage entre 0,25% et 7%. Le principe de dimensionnement et la méthode de sélection du jeu d'entraînement sont les mêmes que ceux qui ont été définis dans le cadre de l'étude précédente. Pour SVM, comme pour RF, chaque classe est caractérisée par le même nombre de pixels d'entraînement. Les effectifs fixés par classe pour chaque taux d'échantillonnage sont présentés dans le tableau 35.

Pour cette analyse, les classifications ont été réalisées en utilisant la série de 5 dates et les 3 bandes spectrales (G+R+NIR) (chapitre II, partie 2.1.2).

Tableau 37: variation du taux d'échantillonnage du jeu d'entraînement.

Taux d'échantillonnage	Effectif total du jeu d'entraînement (pixels)	Effectif par classe (pixels)
0,25%	3 300	550
0,5%	6 600	1 100
1%	13 200	2 200
2,5%	32 952	5 492
4,5%	59 310	9 885
7%	92 262	15 377

1.1.4 Constitution des séries d'images

Organisation temporelle des séries d'images

Les tests reposent sur les images DEIMOS de l'année 2013. A l'échelle du cycle phénologique annuel (figure 68), on a fait varier la composition de la série d'images à classer en prenant en compte entre 1 et 5 dates, et constitué 3 séries d'images :

- série 1 date : 30/07/2013, la plus proche du maximum de végétation,
- série 3 dates : 24/04/2013, 30/07/2013, 23/09/2013, en début, milieu et fin de cycle,
- série 5 dates : 24/04/2013, 30/07/2013, 22/08/2013, 04/09/2013, 23/09/2013.

Il n'a pas été possible de construire une série sur une période supérieure à une année, donc d'intégrer les variations interannuelles à la signature temporelle, comme cela a été fait pour les séries temporelles MODIS. Le facteur « durée » n'est donc pas considéré dans ce chapitre.

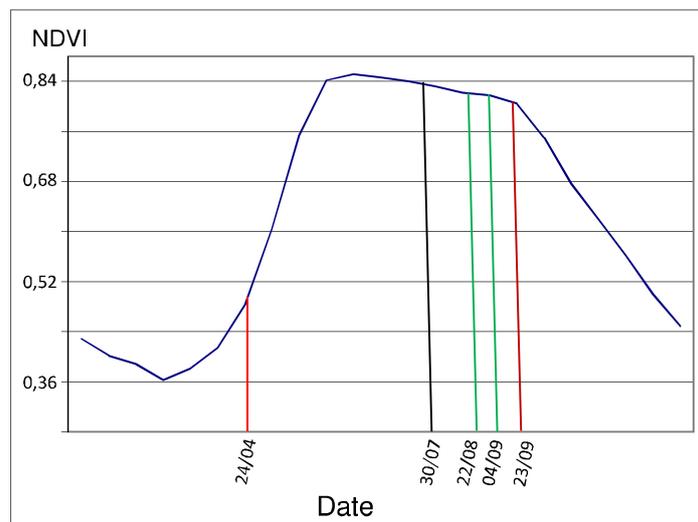


Figure 66: Répartition des dates d'acquisition des images DEIMOS par rapport au cycle phénologique de la hêtraie.

Composition radiométrique des séries d'images

Au total, 6 séries d'images ont été construites, 3 à partir des images de NDVI (1 date, 3 dates et 5 dates) et 3 à partir des bandes spectrales G+R+NIR (1 date, 2 dates et 5 dates).

L'intérêt de l'EVI n'ayant pas été démontré au chapitre précédent, il n'a pas été retenu pour la haute résolution spatiale. Il en est de même pour la bande spectrale MIR, qui par ailleurs n'est pas configurée pour le capteur de DEIMOS.

Ajout de données ancillaires

Comme dans le cas des séries temporelles MODIS, l'ajout de données ancillaires est pris en compte. L'altitude et le rayonnement solaire global, calculés pour le site d'étude HRS, ont été ajoutés aux séries d'images.

Au total, la combinaison des différentes modalités possibles comprend 10 séries d'images présentées dans le tableau 36.

Tableau 38 : nombre total d'images composant les 10 séries étudiées.

Composition radiométrique	Organisation temporelle			Ajout de données ancillaires	
	Série 1 date	Série 3 dates	Série 5 dates	Série 5 dates +Altitude	Série 5 dates +Altitude +Rayonnement solaire global.
Indice de végétation : NDVI	1	3	5	6	7
Bandes spectrales : G+R+NIR	3	9	15	16	17

1.2 Enchaînement des étapes de traitement

Les caractéristiques prises en compte dans la procédure de classification sont analysées en trois étapes relatives successivement au jeu d'entraînement, à l'organisation des séries d'images et aux données ancillaires. L'enchaînement est présenté sur la figure 69.

A chaque étape, des classifications ont été réalisées avec RF et SVM pour les différentes modalités de la caractéristique analysée, les autres restant invariables. La qualité globale des résultats pour ces différentes modalités est évaluée avec l'indice de Kappa à partir du jeu de validation, composé de la totalité des 1 318 033 pixels inclus à 100% dans les polygones de la carte forestière (soit 63890 ha). Comme cela a été précisé pour l'étude précédente, ce jeu de validation permet de calculer les indicateurs de précision et de cartographier la qualité des résultats. Une analyse a été également réalisée par classe afin d'évaluer sur la distinction des formations végétales pour chaque modalité étudiée. Cette analyse est basée sur l'estimation des précisions producteur et utilisateur et du F-score pour les 6 classes.

La première étape (étape 1) porte sur les caractéristiques du jeu d'entraînement. On a fait varier le taux d'échantillonnage selon la gamme précédemment présentée (de 0,25% à 7%), les autres caractéristiques étant fixées. Pour la deuxième étape (étape 2), on a fait varier le nombre de dates et la nature des données images en fixant le taux d'échantillonnage à sa valeur optimale pour les deux algorithmes. La dernière et troisième étape (étape 3) est consacrée à l'étude de l'apport des données ancillaires (altitude et rayonnement global) en fixant les autres caractéristiques à leur valeur optimale.

Comme dans le chapitre précédent, la qualité du résultat obtenu pour la dernière étape a été validée pour chaque algorithme de classification en calculant un indice de Kappa établi à partir des placettes IFN. Ces placettes ne concernant que les milieux forestiers, la validation a été réalisée pour les formations du sapin pectiné, du hêtre et de la forêt mixte hêtre-sapin. Elle concerne 95 placettes localisées dans le site d'étude HRS, dont 75 pour le hêtre, 12 pour le sapin pectiné et 8 pour la hêtraie-sapinière. Les formations non forestières (landes, pelouse et sol nu), qui ne font pas partie de l'inventaire forestier, n'ont pas été intégrées à cette validation complémentaire.

A l'issue de ces différentes étapes, une configuration optimale pour l'établissement de la procédure de classification est proposée pour chaque algorithme.

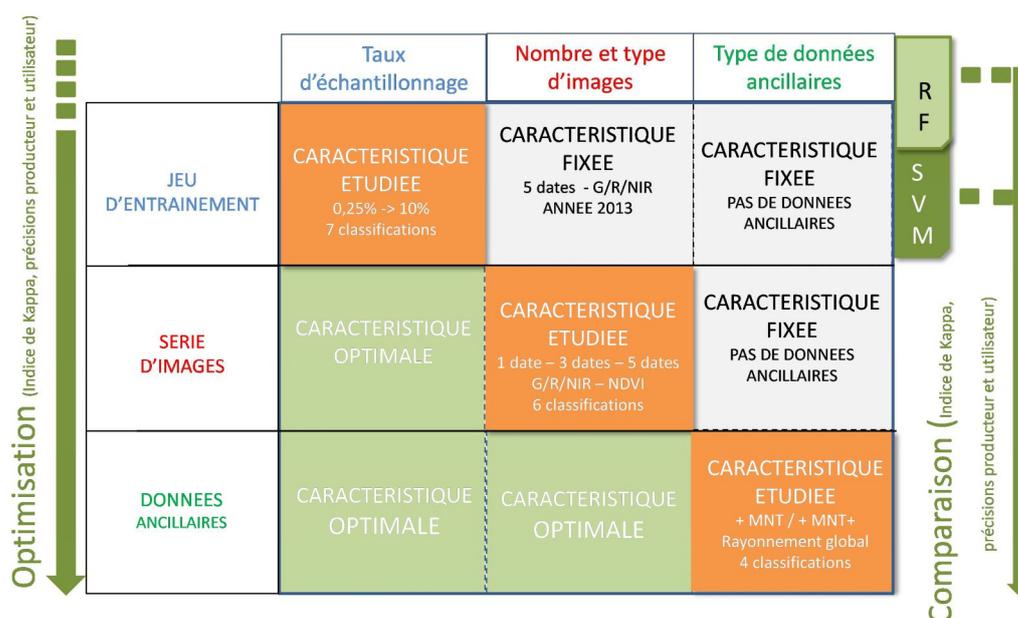


Figure 67: récapitulatif de l'enchaînement des étapes de traitement des séries d'images.

1.3 Interprétation des résultats de classification

Dans cette partie, les classifications ont été réalisées pour les 2 algorithmes en appliquant les configurations optimales retenues. Les résultats sont analysés par classe selon les dimensions spatiale et thématique. Les séries d'images portant exclusivement sur l'année 2013, il n'est pas possible d'analyser la stabilité temporelle interannuelle des résultats, comme dans l'étude précédente.

Le dernier point de l'étude porte sur la comparaison des résultats obtenus avec les images DEIMOS avec les résultats obtenus avec les images MODIS (chapitre IV). L'objectif est d'évaluer, à partir d'un même jeu de validation, l'évolution des valeurs de précision globale, de précision producteur et de précision utilisateur liée au changement de résolution spatiale des données d'entrée.

1.3.1 Analyse spatiale et thématique des résultats

Cette analyse est réalisée en 3 étapes.

Dans une première étape, la qualité des classifications est tout d'abord analysée par classe, à partir du calcul des précisions producteur et utilisateur, des erreurs d'omission et de commission.

L'analyse est ensuite approfondie dans une deuxième étape par l'établissement de la matrice de confusion de la classification présentant les meilleurs résultats. Les valeurs de la matrice sont calculées en surface (ha). Les confusions interclasses les plus importantes sont commentées.

Enfin, dans le but d'étudier la distribution spatiale des pixels bien classés et des erreurs de classification communes aux deux algorithmes, un indicateur de « concordance » a été calculé en troisième étape. On considère comme « concordants » les pixels :

- appartenant à la même classe pour SVM et RF et identiques à la référence,
- appartenant à la même classe pour SVM et RF et différents de la référence.

Les autres situations possibles sont considérées comme « non concordantes ».

1.3.2 Comparaison avec les résultats issus des données MODIS

Cette partie porte sur la comparaison des résultats obtenus avec les images DEIMOS avec ceux obtenus à partir des données MODIS (chapitre IV).

Pour les données DEIMOS, la classification retenue est celle qui produit les meilleurs résultats, pour les 6 classes, avec les modalités suivantes.

Pour les données MODIS, une classification a été réalisée sur le site d'étude HRS, pour les 6 classes. La procédure utilisée est également celle qui apporte les meilleurs résultats.

Pour ces deux classifications, les matrices de confusion ont été établies, sur une même emprise, en utilisant le même jeu de validation, composé de tous les pixels DEIMOS, mixtes ou inclus à 100%, à l'exception des pixels correspondant au masque des zones non forestières à l'échelle MODIS. L'effectif total de cette population est de 1 253 352 pixels, soit une surface totale de 60 755 ha.

Des comparaisons ont ensuite été effectuées à partir des matrices de confusion, des résultats cartographiques des classifications et de la répartition spatiale des pixels bien et mal classés.

Enfin, un croisement a été réalisé entre la carte de stabilité temporelle effectuée à partir des données MODIS et la carte de répartition des pixels bien et mal classés effectuée à partir des données DEIMOS.

2 Résultats

2.1 Détermination des procédures de classification optimales

2.1.1 Choix du taux d'échantillonnage

Analyse globale

La figure 70 présente les résultats obtenus avec SVM et RF pour l'étude de la variation du taux d'échantillonnage.

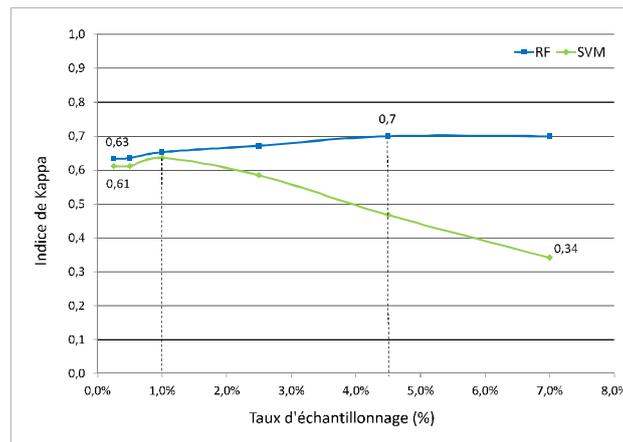


Figure 68: Variation de l'indice de Kappa en fonction du taux d'échantillonnage pour SVM et RF.

On observe une évolution de l'indice de Kappa en fonction du taux d'échantillonnage similaire à celle qui a été observée avec les images MODIS (chapitre IV, partie 3.1.1), cependant les seuils sont différents.

Pour RF et SVM, il augmente de manière similaire jusqu'au taux d'échantillonnage de 1% et l'écart entre les deux algorithmes demeure très faible.

Au-delà de cette valeur, le comportement des deux algorithmes diffère. Pour SVM, l'indice de Kappa diminue fortement et régulièrement, pour atteindre une valeur de 0,34 au taux d'échantillonnage de 7%. Inversement, pour RF, il augmente régulièrement, pour atteindre un plateau vers 0,70.

Pour SVM, il apparaît donc qu'un taux d'échantillonnage de l'ordre de 1% produit le meilleur résultat. Ce taux sera retenu pour la configuration optimale du jeu d'entraînement.

Dans le cas de RF, on obtient rapidement une valeur d'indice de Kappa élevée (0,65 au taux de 1% d'échantillonnage) et plus le taux augmente, meilleure est la précision. On estime que l'augmentation devient négligeable à partir de 4,5%. Il a donc été décidé de conserver 4,5% comme valeur optimale pour le jeu d'entraînement.

Analyse des résultats par classe

▪ Pour SVM

Dans le cas de la situation optimale (taux d'échantillonnage de 1%), les indicateurs de qualité (tableau 37) indiquent que le hêtre est très bien classé. Pour les trois classes suivantes : lande alpine, sapin et pelouse alpine, les résultats peuvent être considérés comme satisfaisants. Dans l'ensemble toutes les valeurs de précision producteur (PP) sont relativement bonnes car supérieures à 55% mais les valeurs

de précision utilisateur (PU) indiquent des erreurs de classification. C'est le cas pour les deux classes sol nu et forêt mixte hêtre-sapin, qui sont caractérisées par une surestimation importante (forte proportion de pixels mal classés) comme l'indiquent les PU, respectivement égales à 31 et 29%.

Tableau 39: valeurs par classe de la précision producteur (PP), de la précision utilisateur (PU) et du F-Score pour un taux d'échantillonnage de 1% et pour SVM.

Taux à 1%	Hêtre	Lande alpine	Sapin	Pelouse alpine	Sol nu	Forêt mixte (hêtre-sapin)
Précision Producteur	81%	71%	70%	55%	87%	60%
Précision Utilisateur	95%	76%	65%	66%	31%	29%
F-score	0,87	0,73	0,67	0,60	0,46	0,39

Comme le montre la figure 71, pour les taux d'échantillonnage inférieurs à 1%, on observe une stabilité de la précision producteur (PP) comme de la précision utilisateur (PU) pour toutes les classes. Pour les taux d'échantillonnage supérieurs à 1%, la qualité se dégrade assez rapidement et le tableau 38 suivant met en évidence les causes de cette dégradation. Pour un taux d'échantillonnage de 7%, seul le hêtre reste bien classé avec un F-score de 0,77. Les classes lande et pelouse alpine sont plutôt sous estimées (la référence est « peu retrouvée ») comme l'indiquent les faibles valeurs de PP). A l'inverse, les classes sapin et sol nu sont fortement surestimées. La forêt mixte est très mal classée, avec un F-score de 0,16.

Tableau 40 : valeurs par classe de la précision producteur (PP), de la précision utilisateur (PU) et du F-Score pour un taux d'échantillonnage de 7% et pour SVM.

Taux à 7%	Hêtre	Lande alpine	Pelouse alpine	Sapin	Sol nu	Forêt mixte (hêtre-sapin)
Précision Producteur	67%	34%	40%	77%	95%	17%
Précision Utilisateur	91%	68%	58%	19%	13%	16%
F-score	0,77	0,45	0,47	0,30	0,23	0,16

▪ Pour RF

Pour la méthode RF, on observe une faible variation des indicateurs de qualité selon le taux d'échantillonnage (figure 71), une légère et régulière augmentation des valeurs de PP et de PU étant observée pour l'ensemble des classes.

Pour le taux de 4,5% (tableau 39), le F-Score maximal est atteint pour le hêtre, avec 0,89, tout comme avec SVM. Les trois classes lande alpine, sapin et pelouse alpine sont correctement classées. Par contre, les classes sol nu et forêt mixte sont fortement surestimées.

Tableau 41: valeurs par classe de la précision producteur (PP), de la précision utilisateur (PU) et du F-Score pour un taux d'échantillonnage de 4,5% et pour RF.

Taux à 4,5%	Hêtre	Lande alpine	Sapin	Pelouse alpine	Sol nu	Forêt mixte (hêtre-sapin)
Précision Producteur	83%	75%	66%	77%	90%	69%
Précision Utilisateur	97%	80%	71%	66%	44%	35%
F-score	0,89	0,77	0,68	0,71	0,59	0,46

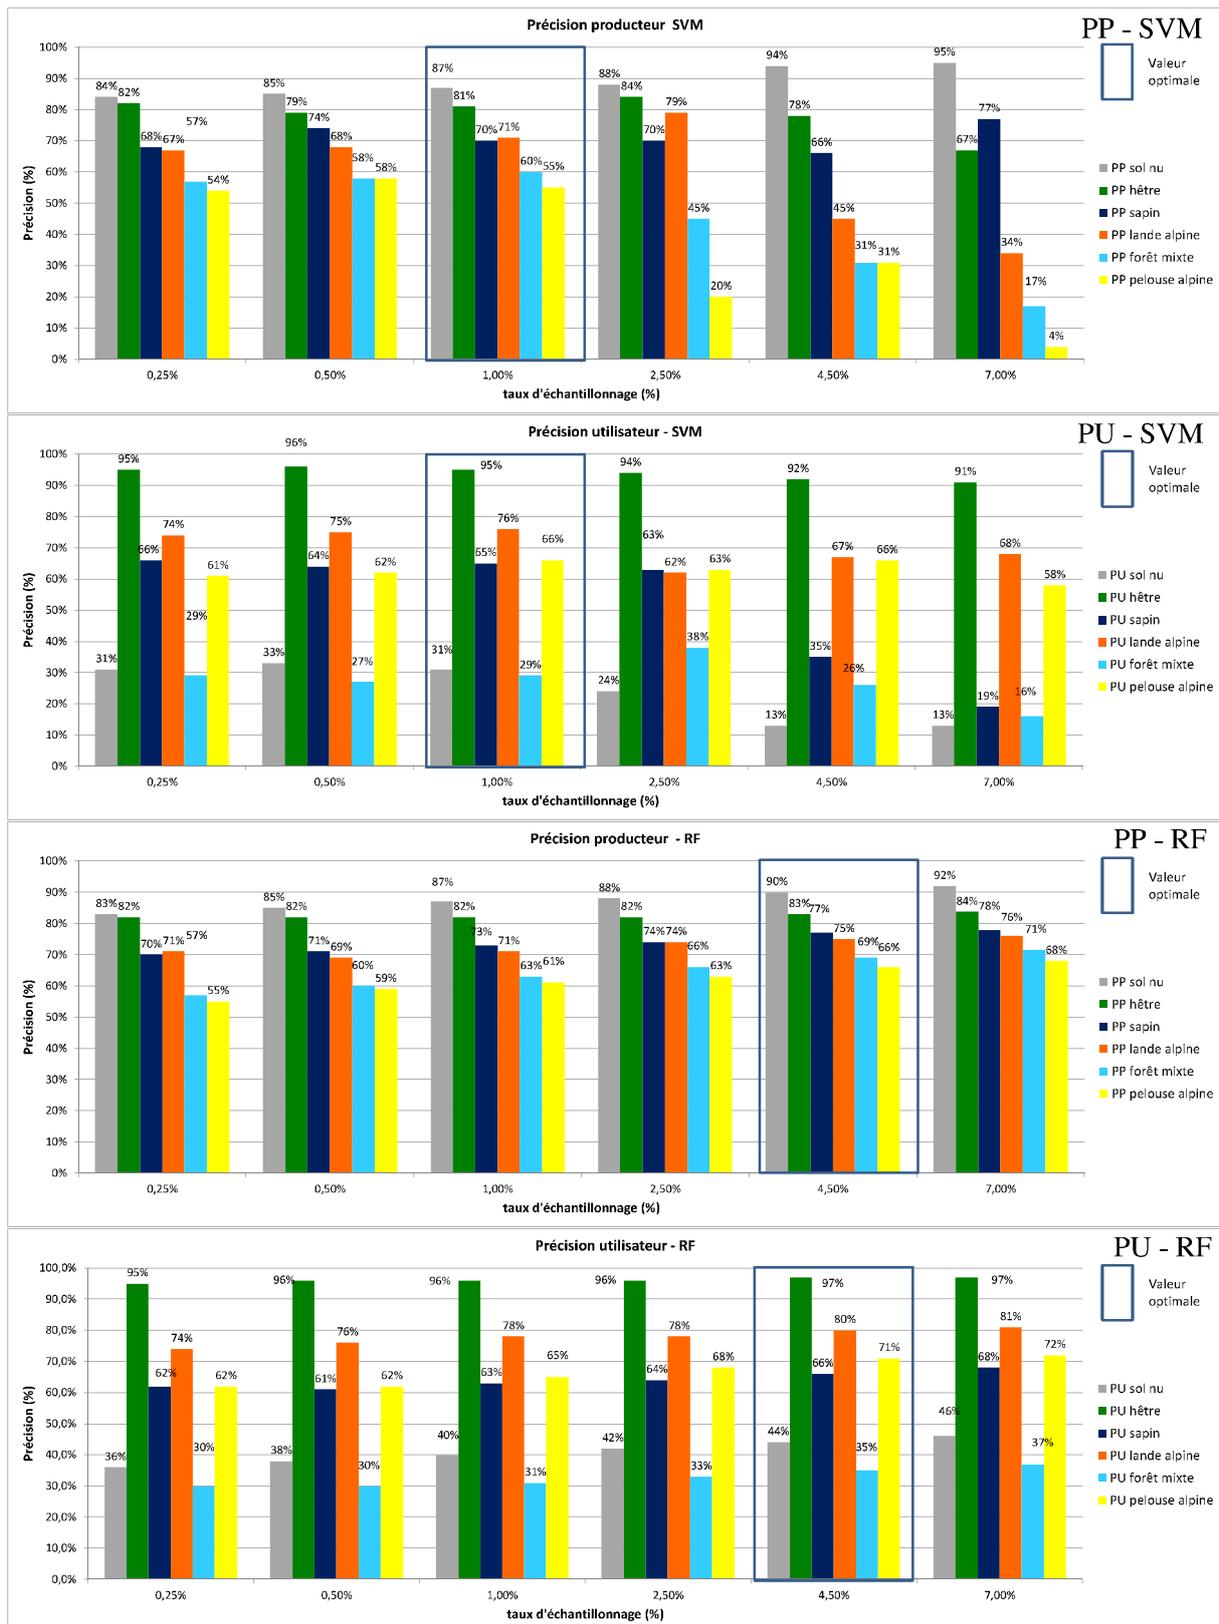


Figure 69: Evolution des précisions producteur (PP) et utilisateur (PU) en fonction du taux d'échantillonnage, pour SVM et RF.

2.1.2 Choix de la composition des séries

2.1.2.1 La série temporelle de NDVI ou de bandes spectrales

Les résultats présentés dans cette partie sont issus de classifications supervisées obtenues en faisant varier la composition radiométrique (NDVI ou bandes spectrales) et l'organisation temporelle (série 1, 3 ou 5 dates). Le taux d'échantillonnage a été fixé à 1% pour SVM et 4,5% pour RF.

Analyse globale

Pour toutes les classifications, on constate que l'augmentation du nombre de dates améliore la qualité (figure 72). L'effet « série » constaté avec les données DEIMOS est donc comparable à celui observé avec les données MODIS.

L'effet lié à la composition radiométrique est également comparable. L'indice de Kappa augmente fortement lorsque l'on utilise les bandes spectrales au lieu de l'indice de végétation. Dans le cas de RF, l'écart de Kappa varie entre 0,25 et 0,31. Pour SVM, il est de l'ordre de 0,21.

De manière générale, on constate que RF produit des résultats légèrement supérieurs à SVM. Cependant, l'écart est moins prononcé que celui qui a été observé avec les images MODIS.

Pour RF comme pour SVM, la configuration optimale retenue pour obtenir les meilleurs résultats de classification est la série 5 dates, composée des 3 bandes spectrales G+R+NIR.

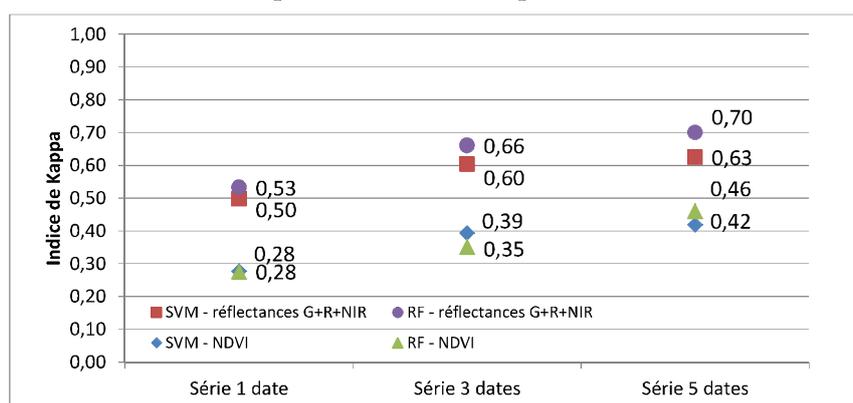


Figure 70: Variation de l'indice de Kappa en fonction de la série, de la composition radiométrique et de l'algorithme (RF et SVM).

Analyse des résultats par classe

Compte tenu des résultats précédents, l'analyse des résultats par classe est réalisée uniquement dans le cas de l'utilisation des bandes spectrales. Les valeurs de PP et de PU obtenues pour les 3 séries sont présentées dans la figure 73.

▪ Pour SVM

On observe que l'ajout de dates se traduit dans la majorité des cas par une augmentation de la PP et de la PU, de 9% en moyenne (tableau 40). Cette augmentation est plus marquée pour les classes lande alpine, sapin et forêt mixte, avec des gains de précision dépassant 15%. La classe pelouse alpine se retrouve nettement moins surestimée (gain de PU de 21 %) par la prise en compte de 5 dates. La classe sol nu n'est pas améliorée. De manière générale, le gain de précision est plus important pour le passage de 1 date à 3 dates (gain moyen de PP de 6%, et de PU de 7%) que pour le passage de 3 à 5 dates (gain moyen de 7% de PP et de 3% de PU). La série 3 dates est relativement bien positionnée sur le cycle phénologique et encadre la saison de végétation (figure 68). Par contre, l'ajout de deux dates

en période estivale n'apporte que peu d'information utile supplémentaire, à l'exception de la forêt mixte pour laquelle la prise en compte de ces 2 dates occasionne un gain de PP de 10%.

Tableau 42: écarts de PP et de PU observés pour SVM et pour chaque classe entre les différents nombres de dates. En gras et noir : gains supérieurs ou égaux à 15%. En gras et rouge : dégradations.

	Hêtre	Lande alpine	Sapin	Pelouse alpine	Sol nu	Forêt mixte (hêtre-sapin)	Ecart moyen
Ecart de PP							
entre 1 et 3 dates	8%	22%	2%	-4%	0%	7%	6%
entre 3 et 5 dates	0%	3%	2%	1%	2%	10%	3%
entre 1 et 5 dates	8%	25%	4%	-3%	2%	17%	9%
Ecart de PU							
entre 1 et 3 dates	1%	6%	8%	15%	2%	7%	7%
entre 3 et 5 dates	1%	3%	7%	6%	-5%	3%	3%
entre 1 et 5 dates	2%	9%	15%	21%	-3%	10%	9%

▪ *Pour RF*

Le gain de précision obtenu par l'augmentation du nombre de dates est assez homogène et plus élevé que dans le cas de SVM (12% en moyenne pour la PP et 13% pour la PU) (tableau 41). L'amélioration la plus importante concerne la classe forêt mixte hêtre-sapin, qui reste cependant la formation la moins bien classée des 6. L'apport des deux dates supplémentaires sur la période estivale (série 5 dates) augmente la précision en moyenne de seulement 2% (PP comme PU).

Tableau 43 : écarts de PP et de PU observés pour RF et pour chaque classe entre les différents nombres de dates. En gras et noir : gains supérieurs ou égaux à 15%. En gras et rouge : dégradations.

	Hêtre	Lande alpine	Sapin	Pelouse alpine	Sol nu	Forêt mixte (hêtre-sapin)	Ecart moyen
Gain de PP							
entre 1 et 3 dates	10%	8%	7%	13%	3%	15%	9%
entre 3 et 5 dates	1%	3%	3%	3%	1%	3%	2%
entre 1 et 5 dates	11%	11%	10%	16%	4%	18%	12%
Gain de PU							
entre 1 et 3 dates	3%	9%	14%	11%	7%	23%	11%
entre 3 et 5 dates	1%	2%	1%	5%	2%	2%	2%
entre 1 et 5 dates	4%	11%	15%	16%	9%	25%	13%

Les résultats confirment, pour les 2 algorithmes, que l'augmentation du nombre de dates de la série d'images permet d'améliorer la précision de classification pour les 6 classes. Cette amélioration est nettement plus importante et homogène pour RF.

Le passage à 3 dates consiste à ajouter des images correspondant au 24 avril et au 23 septembre. Cet ajout permet d'apporter des informations essentielles relatives aux phases de croissance printanière et de sénescence automnale des essences et donc à la caractérisation du cycle phénologique des différentes formations. C'est lors de ces phases phénologiques que les essences ont une activité photosynthétique qui leur est propre et qui les distingue particulièrement les unes des autres.

On peut également interpréter le moindre apport du passage à 5 dates pour la distinction des classes par l'ajout d'informations en partie redondantes avec celles déjà contenues dans la série de 3 dates.

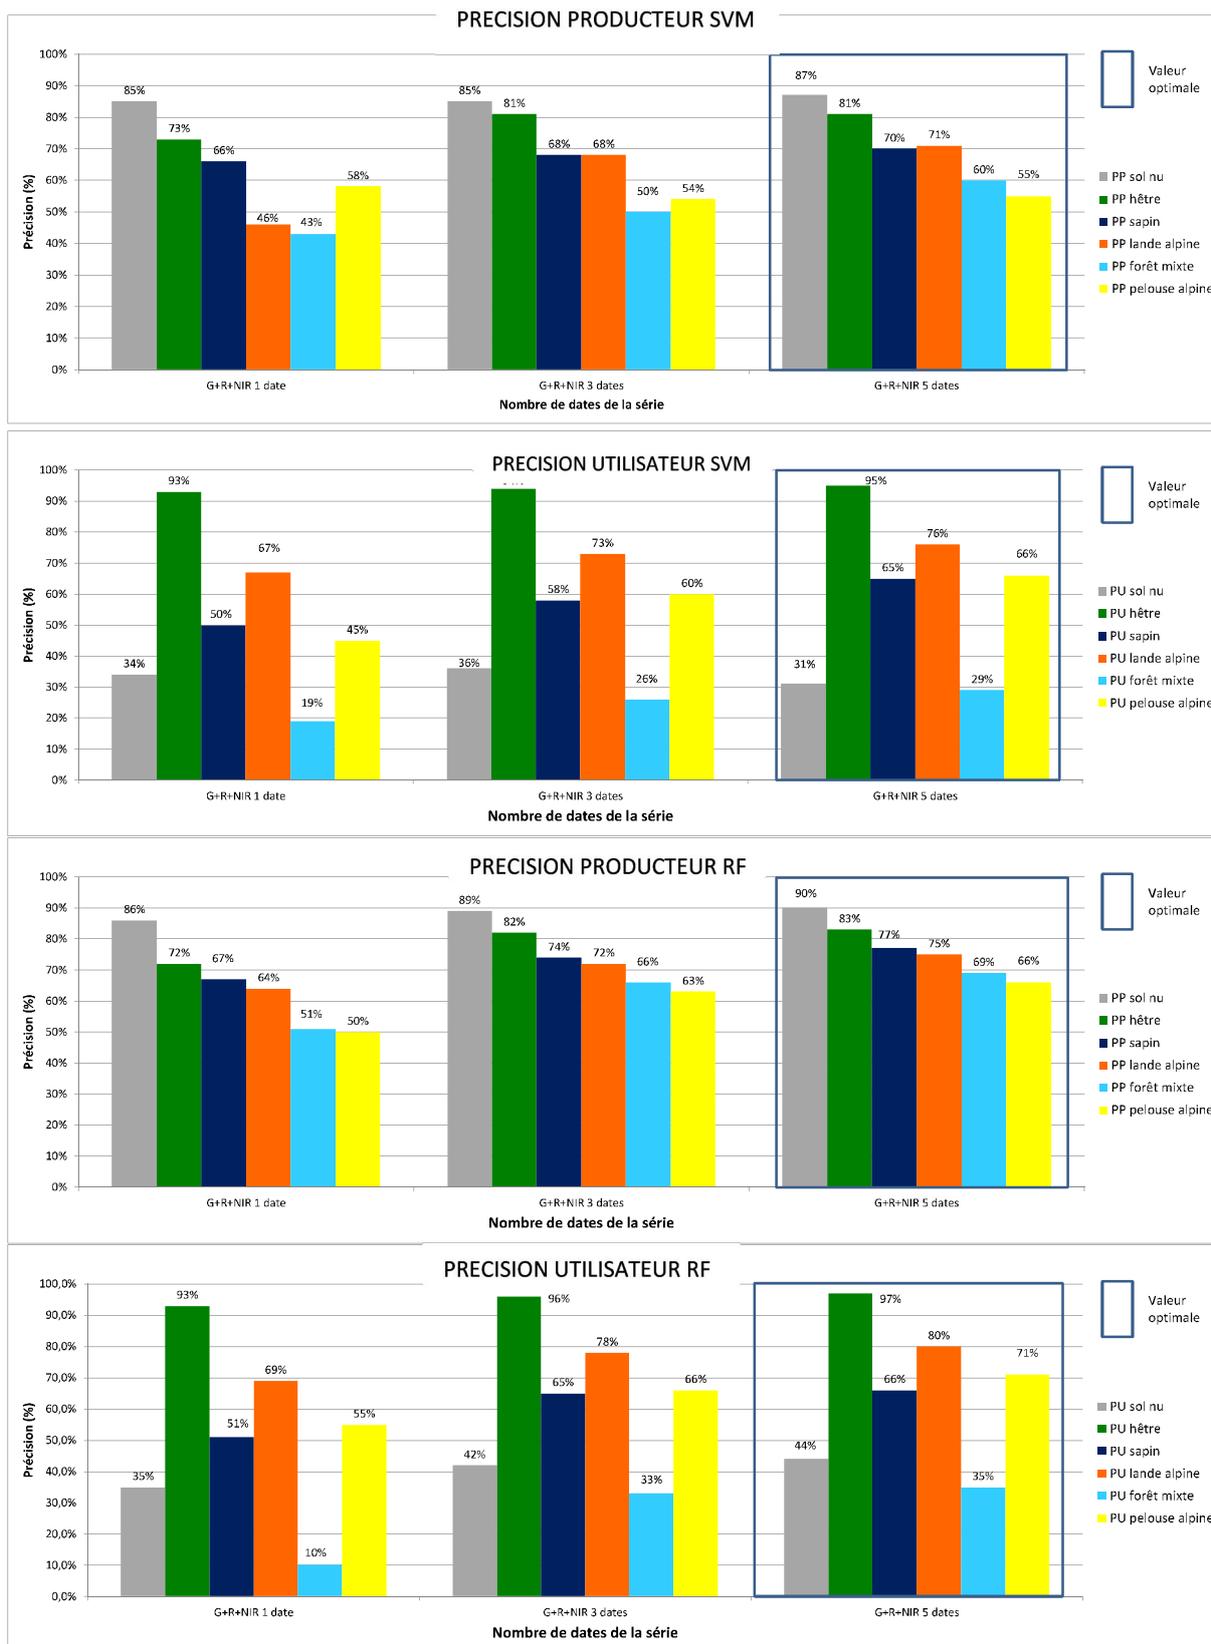


Figure 71: Evolution des précisions producteur et utilisateur et des erreurs d'omission et de commission de la formation du sapin pectiné avec la variation du nombre de dates pour SVM (taux d'échantillonnage optimal de 1%) et RF (taux d'échantillonnage optimal de 4,5%).

2.1.2.2 Apport des données ancillaires

Pour les deux algorithmes, l'ajout de données ancillaires au NDVI apporte une amélioration significative de la classification (figure 74). Pour SVM et RF on note une augmentation de l'indice de Kappa de respectivement 0,15 et 0,19 lorsque l'on complète la série 5 dates avec l'altitude et le rayonnement solaire.

Par contre, l'ajout de ces données ancillaires aux bandes spectrales n'a qu'un très faible impact sur la qualité de la classification, le gain d'indice de Kappa ne dépassant pas 0,05. Dans le cas des données MODIS, cet effet est encore moins prononcé. La différence d'indice de kappa liée à l'ajout des données ancillaires est de seulement 0,02 dans le cas des séries de NDVI comme dans le cas des séries de bandes spectrales, seule l'altitude apportant cette très légère amélioration.

De ce fait, l'écart d'indice de Kappa lié à la composition radiométrique des séries est fortement diminué par l'intégration de l'altitude et du rayonnement dans les modalités de classification.

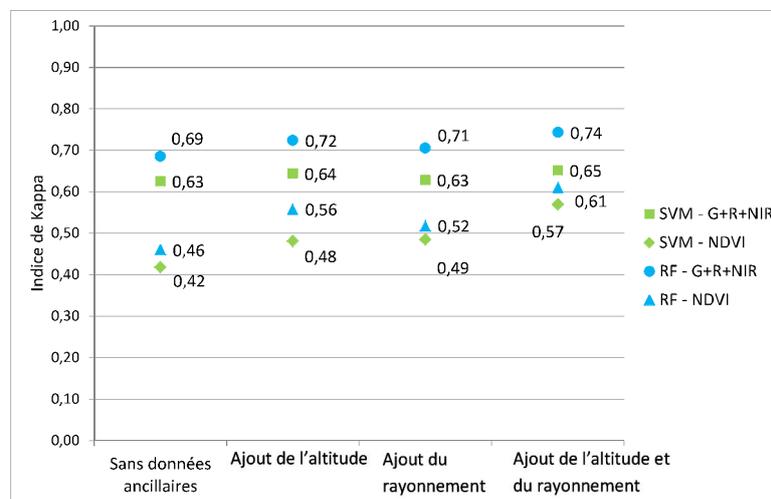


Figure 72: Variation de l'indice de Kappa en fonction de l'ajout de données ancillaires (altitude et rayonnement net global) à la série 5 dates de NDVI et de bandes spectrales, pour RF et SVM.

2.1.2.3 Synthèse

L'ensemble de ces étapes ont montré, comme dans le cas des données MODIS, qu'on peut obtenir des gains de précision variables en fonction de la configuration optimale du jeu d'entraînement, de l'organisation temporelle (l'effet série), de la composition radiométrique (NDVI ou bandes spectrales) et de l'algorithme. Le gain maximal par l'effet cumulé est de 0,48 pour RF et de 0,37 pour SVM (figure 75). Pour chaque étape, les niveaux de précisions sont systématiquement plus élevés avec RF.

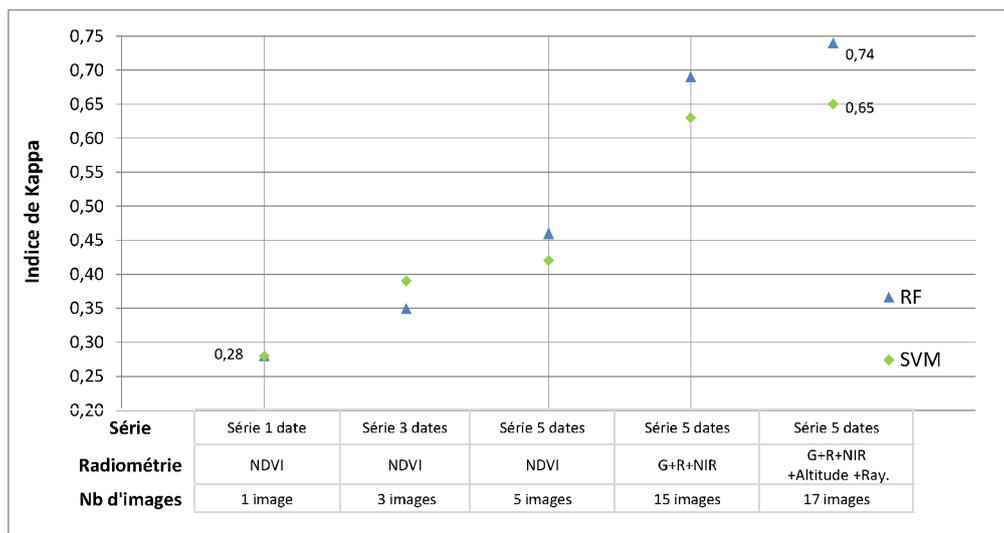


Figure 73 : Evolution de l'indice de Kappa en fonction de l'organisation temporelle et de la composition radiométrique des séries, pour les 2 algorithmes de classification.

Certaines caractéristiques des configurations optimales de RF et SVM identifiées dans cette étude avec les données à haute résolution spatiale sont cohérentes avec celle de l'étude des séries temporelles à moyenne résolution spatiale :

- le faible taux d'échantillonnage pour SVM et le taux d'échantillonnage élevé pour RF,
- l'usage des réflectances plutôt que de l'indice de végétation pour les 2 algorithmes,
- l'ajout de données ancillaires, d'apport toutefois très modéré dans le cas des données MODIS mais par contre important dans le cas des données de NDVI de DEIMOS.

Pour les deux algorithmes, la configuration optimale est présentée dans le (tableau 42). L'utilisation des placettes IFN pour la validation montre de moins bons résultats dans le cas de SVM alors qu'on a observé le phénomène inverse dans le cas des données MODIS. Il faut cependant rappeler que seulement 3 classes sont validées, dont la forêt mixte à hêtre-sapin qui est de loin la classe la moins bien cartographiée.

Tableau 44 : configuration optimale de la série d'images DEIMOS pour les 2 algorithmes de classification.

Algorithme	Configuration optimale du jeu d'entraînement	Organisation temporelle et composition radiométrique optimales des séries	Indice de Kappa (données de référence)	Indice de Kappa (placettes IFN)
SVM	Taux d'échantillonnage : 1%	Série 5 dates, G+R+NIR + Altitude + Ray.	0,65	0,52
RF	Taux d'échantillonnage : 4,5%	Série 5 dates, G+R+NIR + Altitude + Ray	0,74	0,79

La précision de classification maximale est obtenue avec RF, dans ce cas l'indice de Kappa obtenu est de 0,74. Ce résultat doit toutefois être étudié de manière approfondie.

Sur le plan thématique, il convient de déterminer comment cette précision se traduit pour les 6 classes et leurs confusions mutuelles. Dans la partie suivante, on analysera pour chaque classe les valeurs obtenues de précision producteur, précision utilisateur et des erreurs d'omission et de commission.

Sur le plan cartographique, il apparaît pertinent de caractériser la distribution spatiale des erreurs de classification dans le site d'étude.

Enfin, il est intéressant d'établir une comparaison avec les classifications obtenues dans le cadre de l'étude des séries temporelles MODIS, pour déterminer si la précision obtenue pour les 6 classes est améliorée par le changement de résolution spatiale.

2.2 Interprétation des résultats de classification

2.2.1 Analyse spatiale et thématique des résultats

2.2.1.1 Pour SVM

La meilleure classification obtenue à partir de la méthode SVM se caractérise par une bonne distinction de 4 classes sur 6 (figure 76).

En ce qui concerne les **formations forestières**, le hêtre est très bien classé avec très peu de confusions, la seule erreur notable étant une erreur d'omission avec la forêt mixte hêtre-sapin de 15%. Le sapin est aussi très bien classé, les confusions se faisant avec le hêtre et la forêt mixte, avec des erreurs d'omission et de commission cumulées variant de 20 à 25%. On peut aussi noter des erreurs d'omission et de commission d'environ 5% avec les landes, ce qui pourrait correspondre soit à du changement, soit à des imprécisions au niveau de la délimitation des polygones de la carte de référence. Par contre, la classe de forêt mixte hêtre-sapin est mal définie, on note surtout une très forte erreur de commission (61%) avec le hêtre. Il est important de préciser que pour les formations forestières ci-dessus les confusions ont lieu uniquement entre ces formations, puisqu'il n'y a pas, ou peu, de confusions avec les formations non forestières.

S'agissant des **formations non forestières**, les landes et pelouse alpines sont bien classées. Les erreurs de commission, de 16 à 27%, montrent que les confusions se font entre ces deux classes principalement. Par contre, la classe de sol nu n'est pas bien caractérisée, car on peut noter des erreurs de commission dont le cumul est supérieur à 50%, ces erreurs concernant principalement les classes de lande et de pelouse. La classe de sol nu caractérise des zones d'absence de végétation qui n'existent pas à l'intérieur des formations forestières, mais qui sont contiguës aux classes de pelouse et de lande. Cette répartition des erreurs entre les trois classes non forestières est acceptable. En effet, la distinction entre landes et pelouses n'est pas toujours bien indiquée dans les documents de référence. Ces classes regroupent des formations végétales de composition et de physionomie très diverses, dont la disparité n'est pas prise en compte dans la cartographie forestière de référence mais peut être distinguée par télédétection.

2.2.1.2 Pour RF

Pour RF, la répartition des précisions et des erreurs est similaire à celle observée pour SVM (figure 77). On note une amélioration pour le groupe des trois classes forestières, avec une diminution des confusions entre ces trois classes. Pour les classes non forestières, lande, pelouse et sol nu, on remarque aussi une amélioration. Cependant les confusions entre ces trois classes restent identiques, l'amélioration étant due à une diminution des confusions avec les classes forestières.

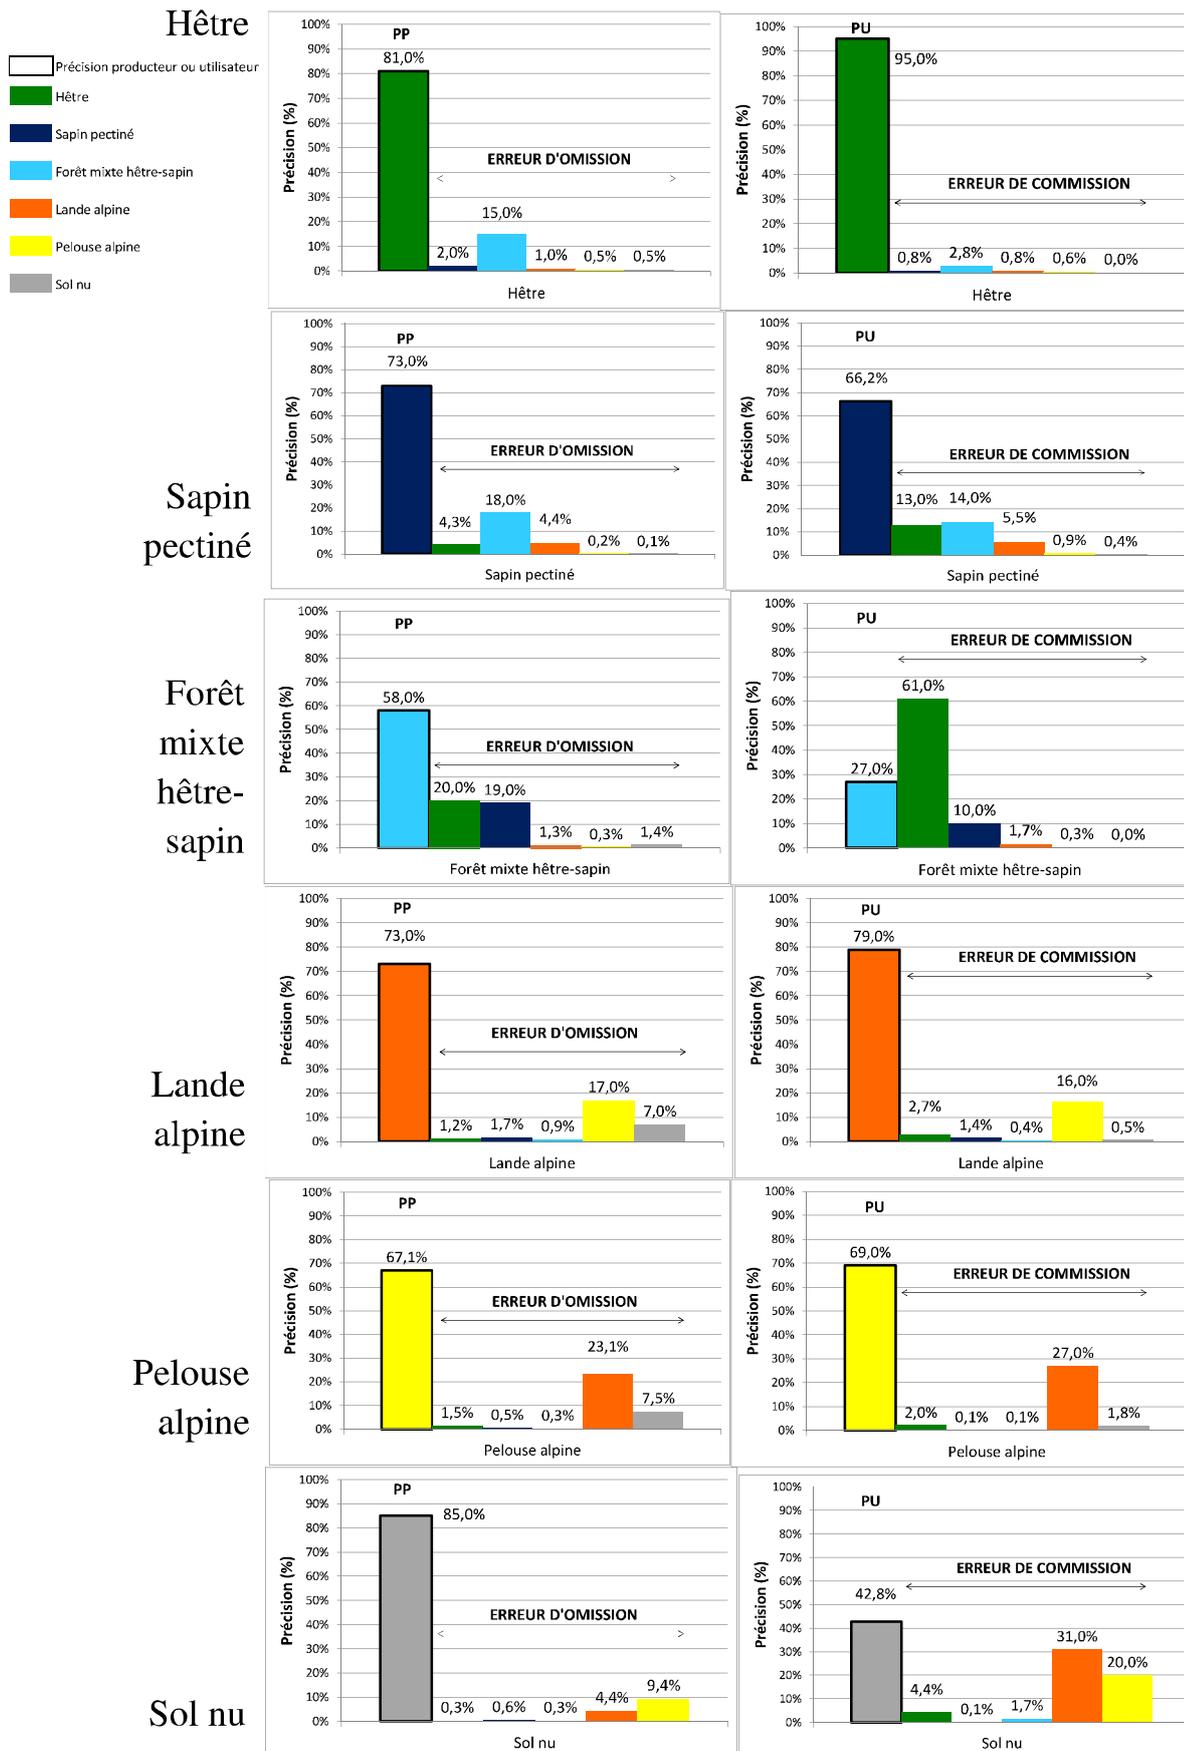


Figure 74: Précision producteur, précision utilisateur et erreur d'omission et de commission de la meilleure classification par la méthode SVM des 6 formations végétales étudiées.

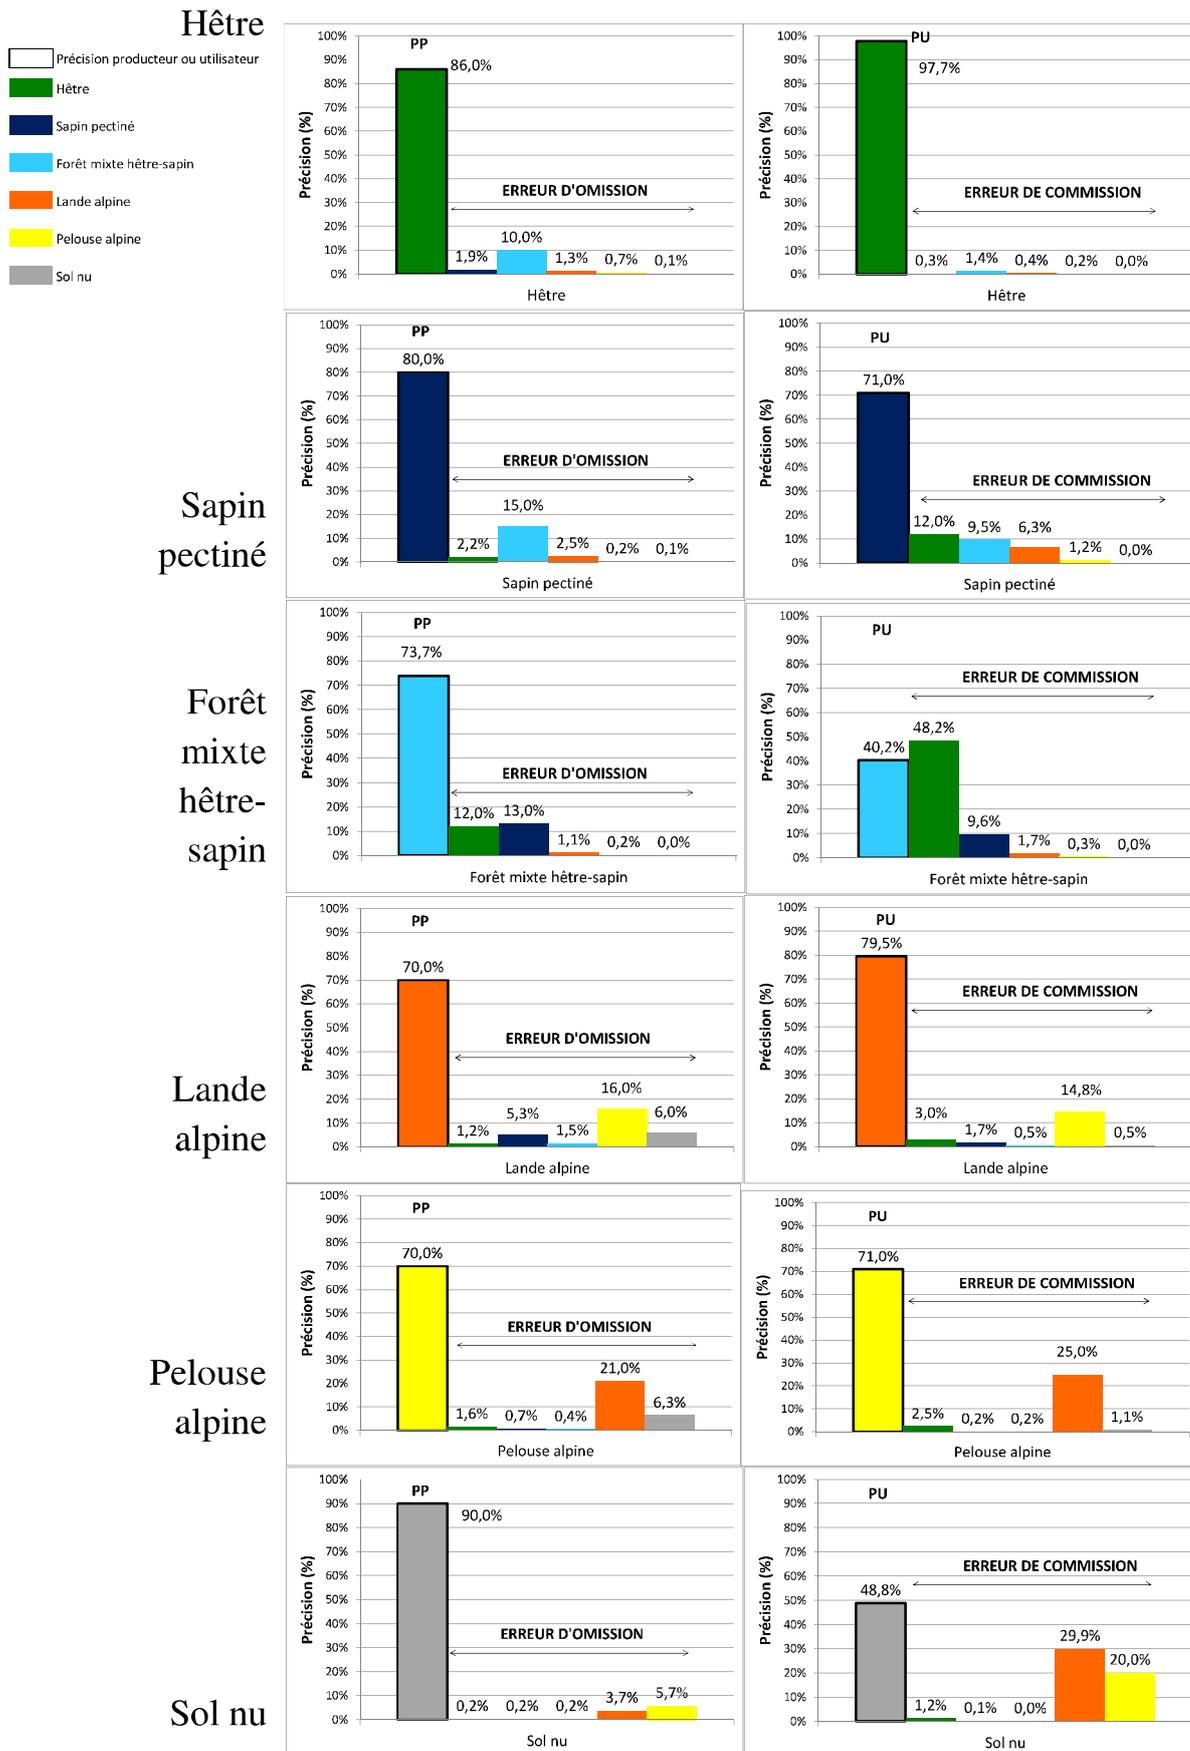


Figure 75: Précision producteur, précision utilisateur et erreur d'omission et de commission de la meilleure classification par la méthode RF des 6 formations végétales étudiées. AFAIRE

Ces valeurs de précision et d'erreurs sont toutefois exprimées en pourcentage de la surface totale occupée par chaque formation végétale, définie par les données de référence. Une estimation relative est donc fournie pour chaque classe, mais elle ne permet pas d'estimer l'effectif de pixels représenté par chaque confusion et d'établir une comparaison de ces effectifs d'une classe à l'autre.

Afin de compléter cette analyse, une matrice de confusion de la meilleure classification produite par la méthode RF a été exprimée en surfaces (hectares) (figure 78). Les surfaces indiquées en vert correspondent aux pixels dont la classe définie par les données de référence est la même que la classe attribuée par la classification (pixels bien classés). Ces surfaces servent de base au calcul de la PP et de la PU. Les autres surfaces correspondent aux confusions composant l'erreur d'omission et l'erreur de commission (pixels mal classés).

Sur l'ensemble de la matrice, deux confusions ont un fort impact sur la qualité globale de la classification :

- 3 169 ha de hêtre classés comme de la forêt mixte hêtre-sapin, soit 5% de la surface totale,
- les confusions entre lande et pelouse qui, cumulées, couvrent 3 246 ha, soit aussi environ 5%.

A l'inverse, la forêt mixte hêtre-sapin ne couvre pas une surface importante ; par conséquent, même si elle est mal classée, cela n'a que peu d'impact sur la qualité globale de la classification. Cependant, présentant un intérêt thématique, elle fait partie des habitats forestiers que l'on souhaite cartographier.

Classification (colonnes)							Total référence (ha et %)
	Hêtre	Sapin pectiné	Forêt mixte : hêtre-sapin	Lande alpine	Pelouse alpine	Sol nu, rochers	
Référence (lignes)							
Hêtre	26 590	590	3 169	336	149	19	30852 48,5%
Sapin pectiné	92	3 380	635	103	7	3	4220 6,6%
Forêt mixte hêtre-sapin	424	454	2 669	38	7	1	3592 5,7%
Lande alpine	98	301	101	11 263	1 716	880	14359 22,6%
Pelouse alpine	58	51	17	1 530	6 712	528	8896 14,0%
Sol nu, rochers	2	1	2	51	66	1 516	1638 2,6%
Total classification (ha)	27 265	4 776	6 593	13 321	8 656	2 946	63556

Figure 76: Matrice de confusion calculée en surfaces (hectares) correspondant à la meilleure classification par RF. Fond vert : surfaces correctement classées. Fond rose : surfaces mal classées supérieures à 500 ha. Gras : surfaces supérieures à 1 500 ha.

Analyse cartographique des résultats

Ici, l'objectif est de déterminer si la distribution spatiale de l'erreur de classification a une signification par rapport aux délimitations fournies par les données de référence. La figure 79 présente ainsi le résultat de classification correspondant à la matrice de confusion (en bas) ainsi que la délimitation des 6 formations végétales étudiées d'après les données de référence (en haut).

Les erreurs de commission identifiées pour la forêt mixte hêtre-sapin peuvent être localisées sur la carte. On observe une extension de la forêt mixte soit dans des polygones de hêtraie (C1 sur figure 79),

majoritairement, soit sur des interfaces entre hêtre et sapin, alors que cette transition n'est pas identifiée dans la référence (C2 sur figure 79).

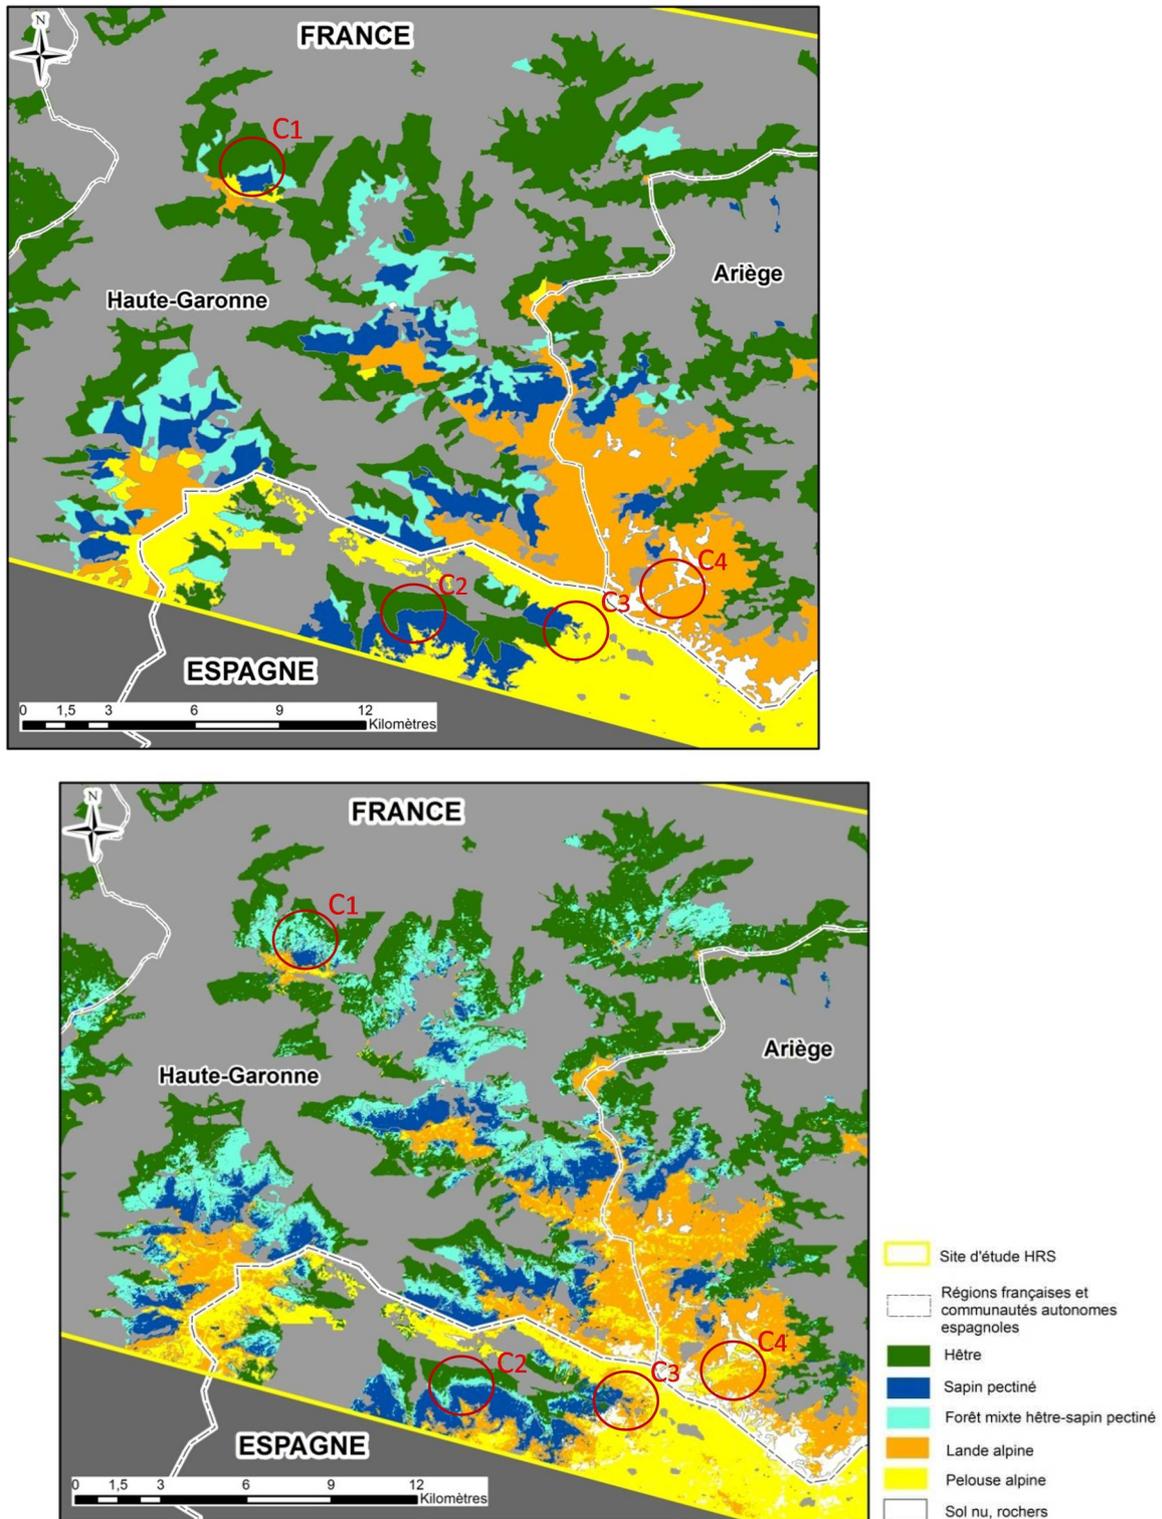


Figure 77 : Extrait de la carte de référence sur le site d'étude HRS (en haut) et de la classification avec RF (en bas) pour les 6 formations végétales étudiées.

Concernant les classes de lande, pelouse et sol nu, la carte de référence présente une situation simplifiée, avec côté français majoritairement des landes et du sol nu, et côté espagnol uniquement de la pelouse. La classification présente, de façon plus réaliste, des gradients lande, pelouse, sol nu, en ajoutant de la lande et du sol nu sur le versant espagnol (C3 sur figure 79) et de la pelouse sur le versant français (C4 sur figure 79).

Une carte combinant les données de référence et les meilleurs résultats de classification produits par les méthodes SVM et RF a été réalisée (figure 80). On remarque tout d'abord que les zones non concordantes (cf paragraphe 2.3.1) sont très peu étendues (en blanc sur la carte). La majorité des pixels sont concordants et classés comme la référence, ce qui atteste de la bonne qualité de classification pour les 2 algorithmes. La distribution des pixels classés différemment par rapport à la référence mais de la même manière par SVM et RF (pixels concordants, en violet sur la carte) permet de retrouver les pixels de commission de la forêt mixte à hêtre-sapin identifiées précédemment (C1 et C2 sur la figure 80). Ceci nous amène à émettre l'hypothèse que la référence forestière n'est pas suffisamment précise pour localiser les peuplements mixtes et/ou que le degré de mixité détectable par télédétection n'est pas équivalent à celui fixé pour l'inventaire forestier. De la même manière, les pixels concordants mais différents de la référence localisés en C3 et C4 sur la figure 80 confirment les probables erreurs de référence pour les classes de pelouse et de lande alpine.

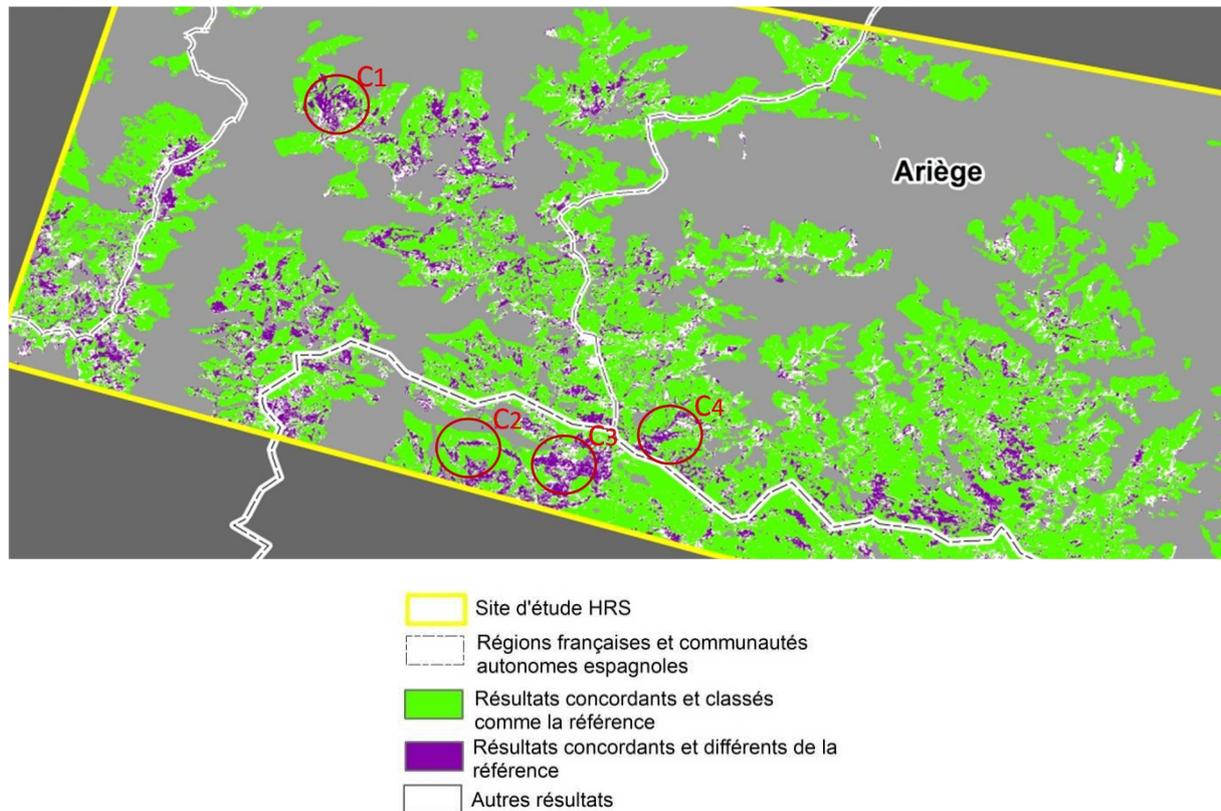
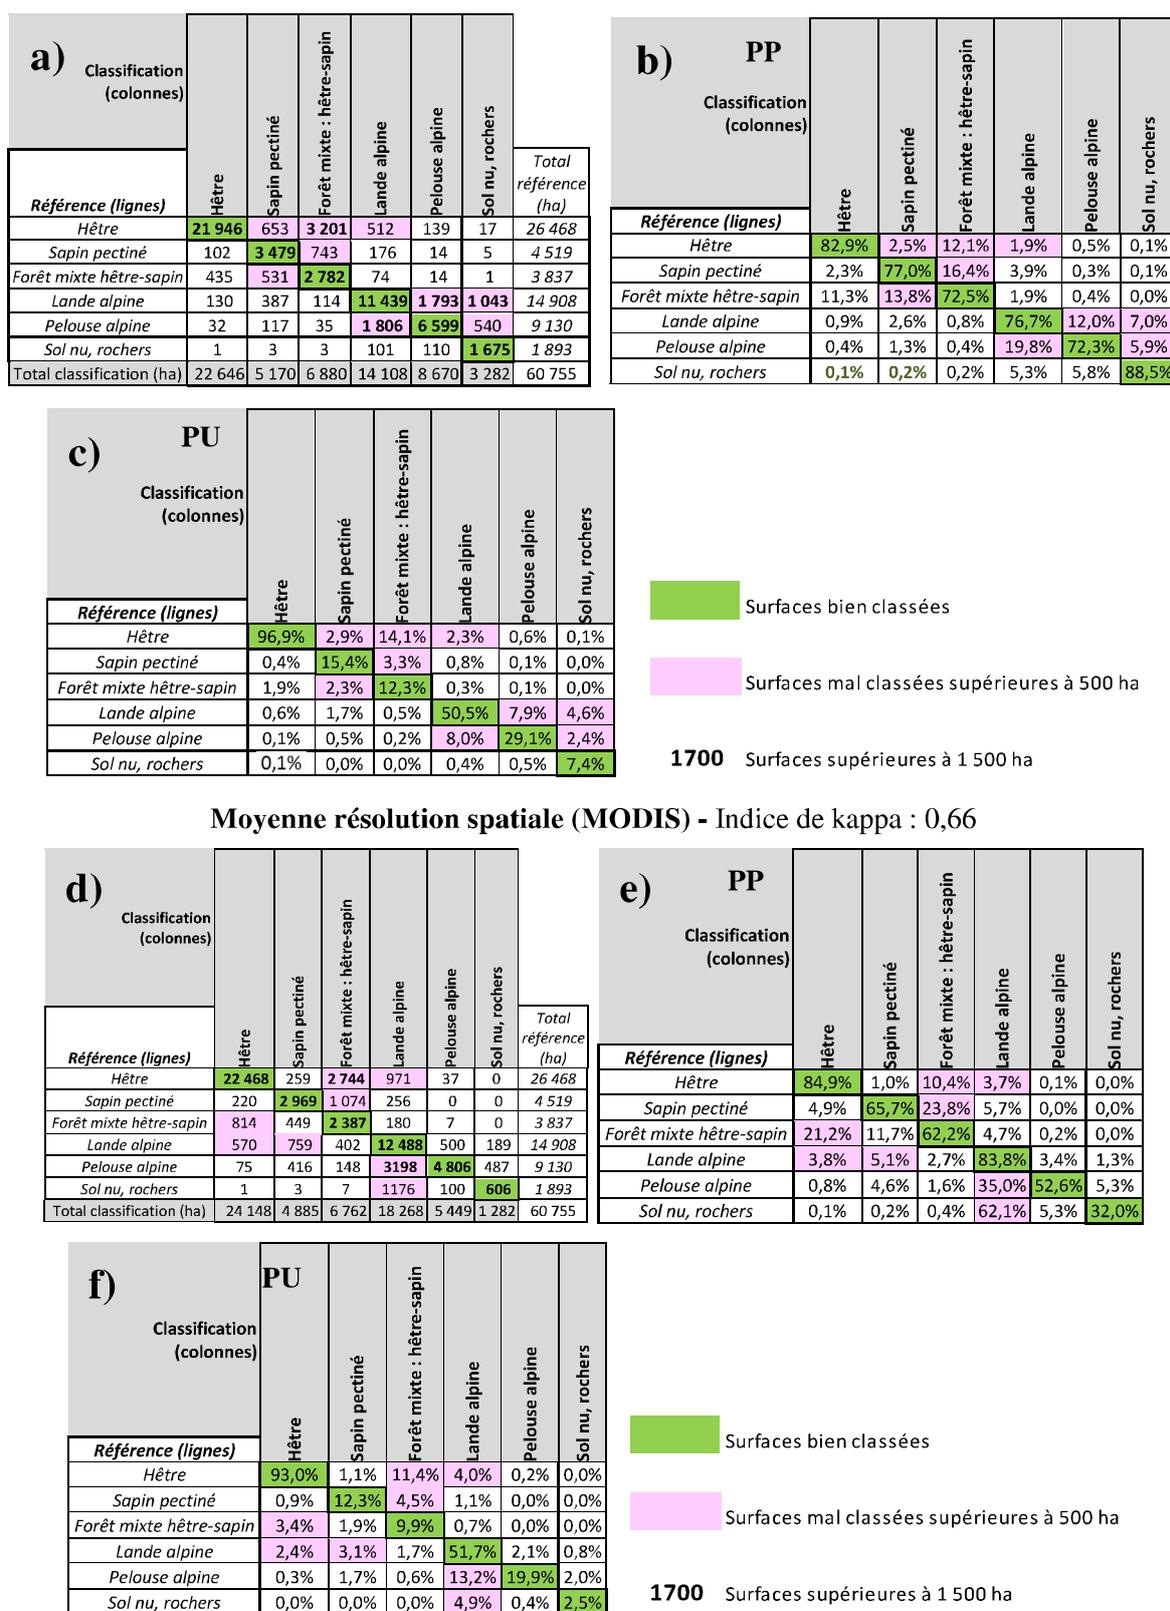


Figure 78: Cartographie des pixels concordants et non concordants pour SVM et RF.

2.2.2 Comparaison avec les résultats issus des données MODIS

Les matrices de confusions, pour les classifications faites avec RF selon les modalités optimales, ont été établies à partir du jeu de validation comprenant tous les pixels DEIMOS, y compris les pixels mixtes (figure 81). Les indices de Kappa obtenus s'élèvent à 0,72 pour la série DEIMOS et 0,66 pour la série MODIS.

Haute résolution spatiale (DEIMOS) - Indice de kappa : 0,72



Moyenne résolution spatiale (MODIS) - Indice de kappa : 0,66

Figure 79: Matrice de confusion calculée en surfaces (hectares, matrices a et d), en pourcentages en lignes (PP et erreur d'omission, matrices b et e) et en pourcentages en colonnes (PU et erreur de commission, matrices c et f) de la meilleure classification par RF des séries temporelles MODIS et des séries d'images DEIMOS.

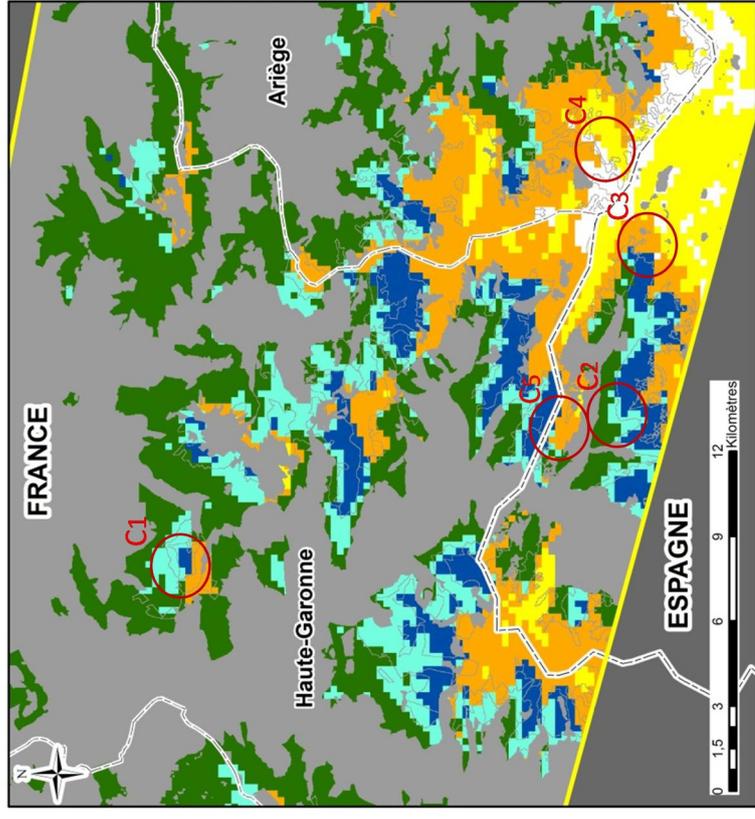
La comparaison des résultats montre qu'on obtient une meilleure classification avec la série DEIMOS. Une amélioration est constatée pour la majorité des classes, sauf dans le cas de la lande alpine. Les valeurs de PP varient entre 72 et 88% selon les classes dans le cas de DEIMOS et entre 32 et 85 % dans le cas de MODIS (figure 81). Les valeurs de PU varient entre 97 et 7% selon les classes dans le cas de DEIMOS et entre 93 et 2,5% dans le cas de MODIS.

Dans les deux cas la hêtraie, et dans une moindre mesure le sapin, sont bien classés et on retrouve le même type de confusion logique avec la forêt mixte hêtre-sapin. L'étendue et la localisation de ces secteurs de confusion sont très similaires, on peut les localiser sur les cartes (C1 et C2, figure 82 a), b) et c)). On peut noter une amélioration du taux de pixels bien classés pour la forêt mixte à hêtre-sapin puisqu'on passe de 62,2% avec MODIS à 72,5% avec DEIMOS.

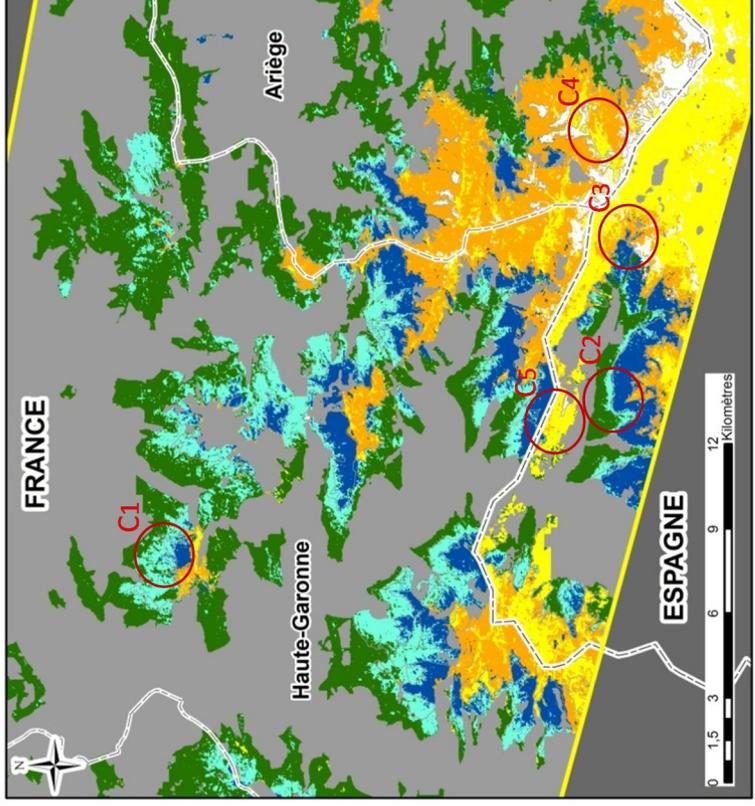
Le deuxième niveau de confusion est également entre les classes lande et pelouse alpine (C3 et C4, figure 82). On note que l'erreur d'omission de la classe lande, au profit des classes pelouse et sol nu, est moins important dans le cas de MODIS, même si dans certains cas (C5, figure 82 a), b) et c)) les pixels classés en lande diffèrent de la référence alors qu'ils sont bien classés sur DEIMOS. A l'opposé, les classes pelouse et sol nu sont moins bien identifiées à partir des images MODIS, avec respectivement des erreurs d'omission de 35 et 62 %.

La proportion de pixels mal classés est nettement plus élevée dans le cas de MODIS, toutefois la répartition spatiale de ces erreurs (figure 82 d) et e)) est relativement similaire à celle de DEIMOS. Cela confirme qu'une part non négligeable de ces situations est probablement liée à la qualité de la référence.

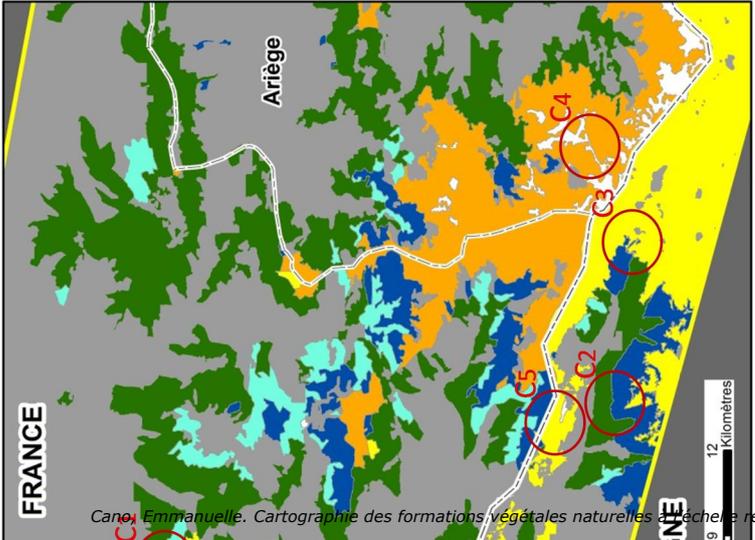
c)



c)

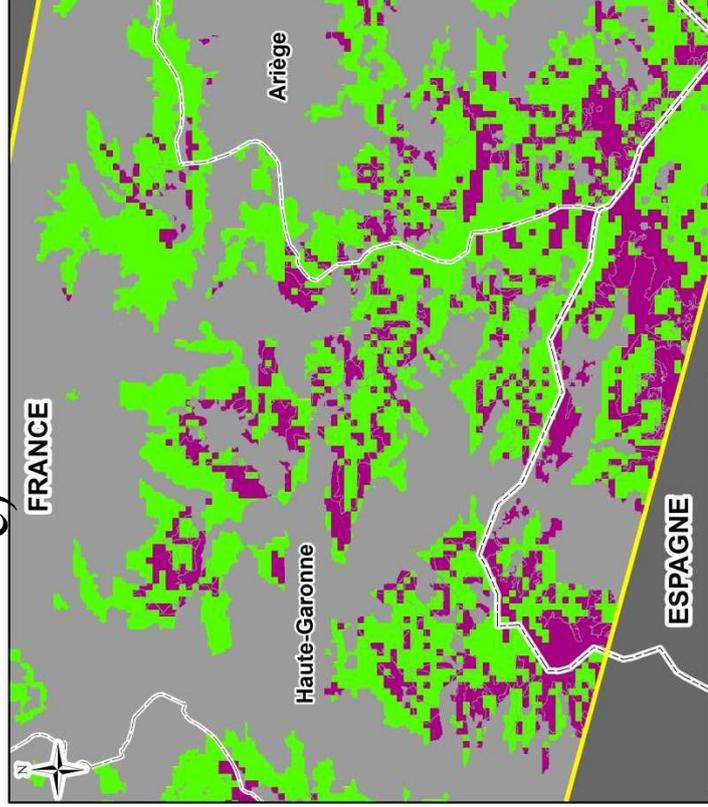


c)

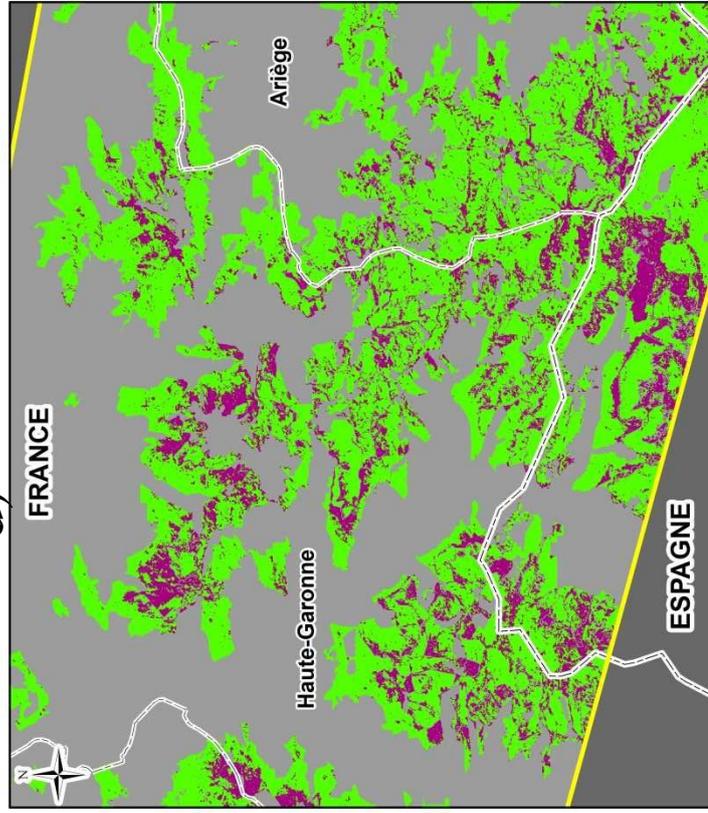


Canou, Emmanuelle. Cartographie des formations végétales naturelles à l'échelle régionale par classification de séries temporelles d'images satellitaires - 2016

e)



d)



de HRS

françaises et
autonomes
les

classé comme la

Pour compléter l'analyse et la comparaison des erreurs de classification entre les classifications issues des séries d'images DEIMOS et MODIS, un croisement a été réalisé entre la carte de stabilité temporelle établie avec MODIS (cf chapitre IV) et la carte des pixels bien et mal classés avec DEIMOS (figure 83). Les pixels DEIMOS mal classés (18% du total) se répartissent entre les 3 classes de stabilité de MODIS, dans des proportions faibles, avec seulement 6% dans la classe « stable et classée comme la référence ». Par contre, on peut constater qu'une forte proportion de pixels bien classés par DEIMOS sont classés stables par MODIS (44% du total). Le deuxième point important est la très forte proportion de pixels classés instables avec MODIS mais bien classés par DEIMOS, ce qui représente 78% des instables, soit 29% du total. Il semble donc que c'est sur ces situations que le changement de résolution spatiale a un rôle d'amélioration prépondérant. Si l'on se réfère à l'analyse qui a été faite dans le chapitre précédent (chapitre IV paragraphe 3.2.1.1) les pixels instables se situent majoritairement sur les limites séparant les types de formations végétales et correspondent probablement à des pixels mixtes dont la signature temporelle est mal reconnue par la classification. Cette observation confirme que le changement de résolution spatiale, en limitant la proportion de pixels mixtes, est le principal facteur d'amélioration des résultats de classification faite avec MODIS.

Tableau 45 : matrice de confusion comparant la carte de stabilité temporelle établie dans le chapitre précédent à la résolution spatiale MODIS (lignes) à la carte des pixels bien et mal classés par rapport à la référence établie à la résolution spatiale DEIMOS.

Carte des pixels bien et mal classés à haute résolution spatiale (DEIMOS) (colonnes)	Résultat classé comme la référence		Résultat différent de la référence		Total (ha)
Carte de stabilité temporelle à moyenne résolution spatiale (MODIS) (lignes)					
Instable	17 348	29%	4 812	8%	22 160
Stable et classé comme la référence	26 174	44%	3 845	6%	30 020
Stable et différent de la référence	5 296	9%	2 309	4%	7 605
Total (ha)	48 818		10 966		59 784

3 Discussion-conclusion

3.1 Bilan sur la détermination des procédures de classification optimales

Les résultats obtenus pour la définition des procédures de classification optimales à partir de la série d'images à haute résolution spatiale confirment sur de nombreux points les conclusions de l'étude précédente basée sur les données MODIS.

Pour ce qui concerne le taux d'échantillonnage du jeu d'entraînement, on observe les mêmes comportements des algorithmes SVM et RF que dans le chapitre IV. La précision de classification obtenue avec SVM est meilleure pour de faibles taux d'échantillonnages et se dégrade au-delà d'un seuil, ici observé à 1%. La précision de classification obtenue avec RF présente une croissance régulière avec l'augmentation du taux d'échantillonnage et stagne autour d'un seuil d'une valeur de 4,5%.

Les valeurs seuils obtenues sont inférieures à celles de l'étude précédente (1% pour SVM et 4,5% pour RF contre respectivement 3,5% et 10%). On peut supposer que l'étendue du site d'étude à traiter influence ces seuils. En effet, le site d'étude HRS étant plus restreint que le site MRS, il présente une variété de formations végétales plus limitée (6 classes contre 24 classes pour MRS). On peut également penser que cette limitation géographique a pour effet de réduire la variabilité spatiale des signatures, ce qui favorise l'atteinte d'une configuration optimale pour un taux d'échantillonnage plus faible. Enfin, ces valeurs sont également explicables si on considère le nombre de variables de la série d'images DEIMOS, beaucoup plus faible que celui de la série temporelle MODIS. La taille du jeu d'entraînement optimale pour les deux algorithmes s'en trouve diminuée. La relation entre taille du jeu d'entraînement, nombre de variables et distribution des signatures représentatives d'une classe a déjà été établie dans la littérature (Foody et al., 2006 ; Pal et Foody, 2010).

Pour l'analyse de la composition de la série d'images, les apports de la temporalité et de la radiométrie sont à nouveau clairement identifiés : quelque soit l'algorithme, la précision de la classification augmente avec le nombre de dates et est nettement plus élevée avec les bandes spectrales qu'avec le NDVI.

Les résultats relatifs à la temporalité ont indiqué un apport plus important du passage de 1 à 3 dates que de 3 à 5 dates. Le passage de 1 à 3 dates a permis de représenter deux phases phénologiques distinctes : la croissance printanière et la croissance estivale. Les deux dates ajoutées pour passer à 5 dates appartiennent également à la phase de croissance estivale et n'apportent pas d'information supplémentaire. Aucune date représentative de la phase de sénescence automnale n'a pu être exploitée. L'ajout d'une ou plusieurs dates représentant la phase de sénescence automnale aurait sans doute été particulièrement utile à la distinction des classes de végétation, car cette phase phénologique est spécifique à chaque essence. Des conclusions similaires ont déjà été établies dans la littérature, telles que l'étude de (Price et al., 2002), qui compare le caractère discriminant de différentes séries multi-dates de bandes spectrales, composées de 1 à 3 dates correspondant aux mois de mai (croissance printanière), juillet (croissance estivale) et septembre (fin de croissance estivale). L'étude conclut à un meilleur apport des séries composées de deux dates et non d'une unique date. Dans le cas de l'ajout d'une troisième date, cet apport est moins avéré : cela peut être dû au fait que les trois dates ne représentent que deux phases phénologiques distinctes et que 2 dates sur 3 sont trop proches dans le temps. Pour ce qui concerne le meilleur apport des bandes spectrales par rapport au NDVI, la même étude aboutit à un résultat inverse dans le cas des séries d'une date, mais met en évidence un apport quasi similaire des deux types de données dès lors qu'on augmente le nombre de dates.

Pour l'analyse de l'ajout de données ancillaires, le même phénomène est observé pour les données MODIS et les données DEIMOS : leur apport à la précision est très faible lorsqu'on traite une série de bandes spectrales, pour SVM comme pour RF. L'apport est par contre significatif dans le cas de séries de NDVI, en particulier pour les données DEIMOS. Ainsi, les données d'altitude et de rayonnement permettraient de compléter l'information fournie par l'indice de végétation pour la distinction des classes. Dans le cas des bandes spectrales, cette information semble redondante ou inutile. Ces conclusions vont dans le sens de l'étude de (Zhu et Liu, 2014), visant à distinguer par classification trois formations forestières à partir d'une série temporelle d'images Landsat (bandes spectrales de 30 m de résolution spatiale). Un gain faible, de 2% de précision globale (overall accuracy) a été observé avec l'usage de données altitudinales issues du SRTM en données ancillaires.

La répétition de l'ensemble de ces phénomènes conforte les conclusions de l'étude précédente et permet de conclure qu'ils ne sont pas liés à un contexte spécifique et qu'ils sont indépendants des données d'entrée et de leur résolution spatiale. Le gain maximal d'indice de Kappa correspondant à l'apport cumulé de l'ensemble des modalités optimales est de 0,37 pour SVM et de 0,48 pour RF. En comparaison, dans l'étude précédente basée sur les données MODIS, le gain maximal observé d'indice de Kappa est de 0,25 pour SVM et de 0,32 pour RF. Ces résultats confirment l'importance de définir une procédure de classification optimale pour obtenir les meilleurs résultats possibles. En effet, l'apport de cette configuration optimale semble encore plus favorable dans le cas de données à haute résolution spatiale.

3.2 Bilan de l'analyse thématique et spatiale

Quelle que soit l'étape de la démarche, on obtient systématiquement de meilleurs résultats avec l'algorithme RF qu'avec SVM, ce qui va également dans le sens des conclusions de l'étude précédente. Cette meilleure qualité se traduit en termes de précision globale (indice de Kappa) mais aussi de précision thématique (précisions producteur et utilisateur).

Ainsi, SVM se caractérise par une dégradation des valeurs de précision producteur et utilisateur pour la quasi-totalité des classes dès que le seuil de taux d'échantillonnage est dépassé. En revanche, RF se caractérise par une stabilité de la qualité des résultats. Lorsqu'on passe du NDVI aux bandes spectrales et qu'on augmente le nombre de dates de la série d'images DEIMOS, une amélioration de la PP et de la PU est observée pour les deux algorithmes. Les valeurs de PP restent plus homogènes pour RF. L'examen des erreurs d'omission et de commission permet d'observer que le recours à RF génère des confusions moins marquées entre les formations forestières. Ces constatations diffèrent des conclusions de plusieurs études, qui mettent en évidence une précision thématique similaire pour les deux algorithmes (Abdel-Rahman et al., 2014 ; Pal, 2005).

Les confusions entre forêt mixte et hêtre d'une part et entre lande et pelouse alpine d'autre part, déjà observées pour les données MODIS, sont à nouveau présentes malgré le changement de résolution spatiale. L'analyse des résultats de classification de la série d'images DEIMOS montre qu'une partie de ces confusions était imputable à des imprécisions dans les données de référence. L'analyse cartographique menée dans la présente étude permet d'approfondir ces conclusions, en caractérisant ces imprécisions. La répartition spatiale des confusions correspond à des zones bien définies et à une grande majorité de pixels concordants mais différents de la référence (secteurs C1 à C4 des figures 80 et 82). La comparaison des cartes obtenues par classification avec la cartographie forestière de référence a mis en évidence des imprécisions liées à une délimitation spatiale simplifiée des

formations végétales. Dans le cas des formations mixtes telles que la forêt mixte hêtre-sapin, on conclut que le degré de mixité pris en compte par la cartographie forestière n'est pas aussi précis que celui caractérisé par télédétection. Ces résultats confirment la forte influence de l'imprécision des données de référence sur la qualité de classification. D'après la carte de concordance obtenue (figure 82), les pixels concordants et différents de la référence, pour l'ensemble des 6 classes, représentent 12,5% de l'effectif total (tableau 43), ce qui n'est pas négligeable.

Tableau 46 : Proportion de pixels concordants et non concordants dans la population de pixels DEIMOS.

	Effectif	Proportion des pixels
Pixels concordants et classés comme la référence	929 431	73,6%
Pixels concordants et différents de la référence	159 424	12,5%
Pixels non concordants	190 251	14,9%

3.3 Bilan de la comparaison avec les résultats issus des données MODIS

Avec les données DEIMOS, la forêt mixte hêtre-sapin est moins bien classée que les formations forestières de hêtraie et de sapinière pures avec les deux algorithmes : le mélange d'essences reste difficile à caractériser, malgré le changement de résolution spatiale. L'apport du changement de résolution sur la précision de classification a toutefois été mis en évidence par la comparaison des deux matrices de confusion issues des données DEIMOS et MODIS pour le site d'étude HRS. L'amélioration de la précision globale se traduit par une augmentation de l'indice de Kappa de 0,6 à 0,72. Pour ce qui est de la précision thématique des résultats, cette amélioration ne concerne cependant que 4 classes sur les 6 (tableau 44). La perte de surface bien classée de lande alpine est de 1049 ha, ce qui représente 6,8% de la surface totale de cette formation dans le site d'étude HRS d'après les données de référence. Dans le cas du hêtre, la PP est très légèrement dégradée. La perte de surface bien classée correspond à environ 520 ha, ce qui représente 1,6% de la surface totale de hêtre dans le site d'étude HRS. Pour les autres classes, les gains de PP observés sont très variables mais importants pour les 4 classes, variant entre +10,3 et +56,5%. Les gains de PU concernent 5 classes et sont relativement plus faibles et plus homogènes, avec des valeurs variant de 2,4 à 9,2%. Pour la classe lande alpine seule, la PU diminue légèrement.

Tableau 47 : Ecart de PP et de PU liés au changement de résolution spatiale et observés pour chaque classe.
Gras : gain de PP ou de PU.

	Ecart de PP (PP_{DEIMOS}-PP_{MODIS})	Ecart de PU (PU_{DEIMOS}-PU_{MODIS})
Hêtre	-2%	+3,9%
Sapin pectiné	+11,3%	+3,1%
Forêt mixte hêtre-sapin	+10,3%	+2,4%
Lande alpine	-7,1%	-1,2%
Pelouse alpine	+19,7%	+9,2%
Sol nu	+56,5%	+4,9%

Même si on observe toujours les confusions déjà mises en évidence dans l'étude précédente, on peut ainsi déduire de ces résultats que le changement de résolution spatiale permet de les réduire de façon significative pour la majorité des classes. Si on s'intéresse plus particulièrement au mélange d'essences forestières représenté par la forêt mixte hêtre-sapin, on observe une augmentation nette de la PP et une petite amélioration de la PU. A titre de repère, le gain de surface bien classée correspond à environ 395 ha, soit 8,4 % de la surface totale de forêt mixte dans le site d'étude HRS.

Ces résultats permettent d'obtenir une première confirmation de notre hypothèse de départ, à savoir l'amélioration de la distinction d'un mélange d'essences grâce au changement de résolution spatiale des données d'entrée de classification. La matrice de croisement de la figure 83 permet d'identifier que 78% des pixels instables obtenus à partir de la classification des données MODIS correspondent à des pixels bien classés à partir des données DEIMOS. La distribution spatiale de ces pixels instables permet d'obtenir une deuxième confirmation de notre hypothèse de départ, en établissant que cette amélioration est majoritairement due à la diminution du nombre de pixels mixtes.

Cette étude fait l'objet d'une publication qu'il est prévu de soumettre avant fin 2016 :

Cano, E., Denux, J.P., Hubert-Moy, L., et Chéret, V., Comparison of forest cover mapping using MODIS time series and multirate high spatial resolution images.

Conclusion générale

Malgré la multiplication constante du nombre de capteurs d'observation de la Terre, les données de télédétection disponibles jusqu'à présent ne permettaient pas de réaliser une cartographie détaillée des formations forestières d'un territoire à une échelle régionale. Nous avons toutefois émis l'hypothèse qu'il était possible de répondre à ce besoin cartographique en appliquant une procédure de classification supervisée par pixel à une série temporelle d'images satellitaires. Atteindre cet objectif en produisant des résultats ayant une qualité et une précision suffisantes reste néanmoins délicat.

L'objectif principal de cette thèse était d'améliorer la procédure de classification supervisée d'une série temporelle afin de produire des cartes forestières à l'échelle régionale.

Sur le plan thématique, nous avons cherché à caractériser, de la façon la plus détaillée possible, la végétation forestière en identifiant les peuplements purs ou les mélanges d'essences forestières, en se rapprochant le plus possible de la nomenclature des inventaires forestiers nationaux. Sur le plan méthodologique, nous avons cherché à définir la configuration optimale de la procédure de classification supervisée permettant d'obtenir les meilleurs résultats.

Afin d'atteindre ces objectifs, nous avons constitué plusieurs séries temporelles d'images optiques à partir d'images à moyenne résolution spatiale MODIS. D'une façon générale, les résultats obtenus ont montré qu'il est possible de distinguer et de cartographier des formations forestières à l'échelle régionale avec une précision globale et thématique satisfaisante.

Plus précisément, nous avons évalué l'apport de la stratification du site d'étude pour améliorer les résultats de classification d'une série temporelle d'images à moyenne résolution spatiale MODIS. La stratification étudiée a été construite à partir d'une segmentation orientée objet. L'analyse des résultats de la classification supervisée effectuée avec l'algorithme du maximum de vraisemblance nous a permis de constater que l'usage de la stratification permettait d'augmenter de façon significative la précision des résultats, mais que ce processus s'accompagnait d'une augmentation du taux de pixels non classés. L'amélioration observée, variable selon les classes, est plus importante pour les classes dont les pixels sont les moins bien classés initialement. En outre, nous avons constaté que l'amélioration des résultats ne dépendait pas des caractéristiques paysagères et topographiques, mais était fortement liée à la surface de chaque strate et à la surface de végétation à classer. Deux seuils critiques ont ainsi été mis en évidence :

- Au-delà de 450 000 ha et lorsque la surface de végétation est supérieure à 120 000 ha, la stratification n'a pas d'effet sur la précision,
- En-dessous de 100 000 ha et lorsque la surface de végétation est inférieure à 5 000 ha, la précision est fortement dégradée par un taux de rejet trop important.

La surface de strate est très dépendante de la valeur du paramètre d'échelle de la segmentation orientée objet. La valeur du paramètre d'échelle et l'indice de texture retenus sont identiques à ceux qui ont été définis dans le cadre d'une autre étude appliquant une méthode identique sur l'ensemble du territoire français, ce qui conforte la robustesse et le caractère reproductible de la méthode. Cette étude a confirmé que la méthode de segmentation orientée objet pourrait constituer une alternative -objective et reproductible- aux stratifications reposant sur un savoir expert. Une perspective intéressante serait de comparer les résultats obtenus à partir de la segmentation orientée objet d'une part à ceux produits

avec une stratification basée sur un savoir expert et d'autre part à ceux produits par un découpage géométrique régulier. Une telle comparaison permettrait de montrer l'intérêt et les limites éventuelles de la méthode par rapport aux techniques de stratification classiques.

Nous avons aussi étudié l'influence de l'organisation de la série temporelle et du choix de l'algorithme sur la qualité des résultats de la classification. Cette évaluation a été effectuée pour trois algorithmes (Maximum de Vraisemblance, Support Vector Machine, Random Forest) en faisant varier les données d'entrée, tant au niveau de la série temporelle elle-même (variables dérivées de la série, organisation de la série) que des données ancillaires utilisées. Les résultats mettent en évidence que l'effet de la temporalité, de la durée et de la radiométrie sur la précision de la classification est particulièrement significatif, l'utilisation d'une série temporelle d'une durée de plusieurs années étant préférable à une série d'images multi-dates, et une série de bandes spectrales étant préférable à une série de NDVI ou d'EVI. De plus, les résultats soulignent la supériorité de l'algorithme Random Forest sur les deux autres. Sur le plan thématique, des confusions subsistent et certains mélanges d'essences sont mal distingués. D'autre part, l'algorithme Random Forest est particulièrement mis en avant, la précision globale obtenue étant systématiquement plus élevée avec RF qu'avec SVM et ML. Cette meilleure qualité se traduit également pour RF par une précision thématique plus élevée ainsi qu'une forte stabilité temporelle des résultats. Les travaux relatifs à l'interprétation thématique et spatiale des résultats a permis de caractériser les causes des confusions et erreurs de classification subsistant malgré l'utilisation de la configuration optimale de la procédure. L'identification avec RF d'une forte proportion de pixels stables sur le plan temporel mais mal classés a ainsi permis de mettre en évidence des imprécisions dans la cartographie forestière de référence. L'analyse critique de cette dernière montre une mauvaise prise en compte des gradients de végétation progressifs entre les classes, la présence de pixels mixtes et des erreurs de calage des images. L'étude approfondie des résultats par classe met en évidence trois ensembles de confusions particulièrement notables : un ensemble de feuillus caducs, un ensemble lande alpine, pelouse alpine et sol nu, et un ensemble hêtre, sapin pectiné et forêt mixte hêtre-sapin. Cette dernière, correspondant à un mélange d'essences, reste plus mal caractérisée que les autres. Sur le plan spatial, ces confusions correspondent à des polygones de la cartographie forestière de référence ou à des alignements de pixels le long des limites de ces polygones.

Nous avons alors cherché à évaluer l'apport du changement de résolution spatiale des images composant la série temporelle utilisée sur les résultats de la classification, notamment pour améliorer la distinction de mélanges d'essences forestières. Les résultats obtenus en classant une série multi-dates d'images DEIMOS confortent les conclusions effectuées précédemment avec les données MODIS sur l'effet de la temporalité et de la radiométrie et la supériorité de l'algorithme Random Forest, ce qui permet de conclure qu'ils sont indépendants des données d'entrée et de leur résolution spatiale. Ils ont aussi démontré qu'une amélioration significative était apportée, en passant des données MODIS aux données DEIMOS, avec une augmentation de l'indice de Kappa de 0,6 à 0,72 obtenue grâce à la diminution de la proportion de pixels mixtes. L'interprétation spatiale et thématique des résultats a permis de mieux caractériser l'origine de certaines confusions, identifiées précédemment. On observe à nouveau les ensembles de confusions entre les classes lande alpine, pelouse alpine et sols nus, et entre les classes hêtre, sapin pectiné et forêt mixte hêtre-sapin. Sur le plan spatial, les confusions sont localisées dans les zones concentrant des pixels concordants entre les 2 algorithmes étudiés mais classés différemment de la référence. Ces résultats confirment les erreurs ou les imprécisions dans la cartographie forestière de référence. La comparaison des précisions obtenues à partir des séries à moyenne et à haute résolution spatiale a indiqué que le changement de résolution

spatiale améliorerait les résultats de classification et notamment la distinction du mélange d'essences (forêt mixte hêtre-sapin). Elle a permis également d'observer que 78% des pixels instables obtenus en moyenne résolution spatiale étaient bien classés en haute résolution spatiale, ce qui confirme que l'amélioration liée au changement de résolution est lié à la diminution de la proportion de pixels mixtes.

Quelle que soit la résolution spatiale des images utilisées, l'analyse de la procédure de classification supervisée des séries temporelles, appliquée ici à la cartographie forestière, montre que la définition d'une configuration optimale améliore sensiblement les résultats de la classification.

L'originalité de ce travail de thèse réside dans la recherche :

- d'une précision thématique élevée pour un territoire de vaste étendue ;
- d'une optimisation des choix définissant la procédure de classification supervisée préalablement à sa mise en œuvre.

Dans la grande majorité des travaux portant sur la classification de la végétation à partir de données de télédétection, ces deux aspects sont fixés au démarrage de l'étude. Ainsi, pour traiter un territoire de grande étendue, on a souvent recours à une nomenclature moins détaillée que celle que nous avons utilisée, afin d'éviter de se heurter aux limites de la classification supervisée. Nos travaux démontrent qu'il est possible de réaliser des cartes détaillées de la végétation forestière à l'échelle régionale avec une précision satisfaisante, à condition de mener une réflexion préalable à l'application de la classification visant à en optimiser la procédure. Cette approche reste délicate à mettre en œuvre et peut être consommatrice de temps, toutefois, nos résultats permettent de fournir des repères sur la nature des optimisations à rechercher.

Plusieurs perspectives peuvent être envisagées à partir de ces travaux de thèse. La majorité des classifications menées dans le cadre de ces travaux sont basées sur des séries temporelles à moyenne résolution spatiale. Nos résultats ont confirmé l'apport de ces séries temporelles pour obtenir une cartographie de la végétation à l'échelle régionale. Ils ont également montré l'apport du passage des données à moyennes résolution spatiale à des données à haute résolution spatiale pour améliorer la précision globale et thématique des résultats. Dans ce contexte, il serait intéressant d'appliquer la démarche de classification développée ici à une série temporelle de données Sentinel-2, qui présente l'intérêt de combiner une haute répétitivité temporelle et une haute résolution spatiale. L'usage de telles données devrait ainsi permettre d'atteindre une meilleure précision globale, mais surtout une meilleure précision thématique grâce à la diminution du taux de pixels mixtes. Il pourrait aussi être intéressant d'évaluer l'apport d'autres données d'entrée sur la précision des classifications, telles que des données hyperspectrales ou LIDAR, l'intérêt de ces données pour cartographier les gradients de végétation étant actuellement mis en avant dans la littérature.-Par ailleurs, il serait intéressant d'étudier d'autres algorithmes de classification présentant des règles de décision différentes de celles des algorithmes étudiés, comme les réseaux neuronaux, pour voir si un comportement différent est observé et si une meilleure précision est atteinte..

Bibliographie

- Abdel-Rahman, E.M., Mutanga, O., Adam, E., et Ismail, R. (2014), Detecting Sirex noctilio grey-attacked and lightning-struck pine trees using airborne hyperspectral data, random forest and support vector machines classifiers, *ISPRS Journal of Photogrammetry and Remote Sensing*, 88, p. 48-59.
- Alcantara, C., Kuemmerle, T., Baumann, M., Bragina, E.V., Griffiths, P., Hostert, P., Knorn, J., Müller, D., Prishchepov, A.V., Schierhorn, F., Sieber, A., et Radeloff, V.C. (2013), Mapping abandoned agriculture with multi-temporal MODIS satellite data, *Remote Sens. Environ.*, 124, p. 334.
- Alcantara, C., Kuemmerle, T., Prishchepov, A.V., et Radeloff, V.C. (2012), Mapping abandoned agriculture with multi-temporal MODIS satellite data, *Remote Sensing of Environment*, 124 (0), p. 334-347.
- Alcaraz-Segura, D., Paruelo, J., et Cabello, J. (2006), Identification of current ecosystem functional types in the Iberian Peninsula, *Global Ecology and Biogeography*, 15 (2), p. 200-212.
- Ali, A., de Bie, C.A.J.M., Skidmore, A.K., Scarrott, R.G., Hamad, A., Venus, V., et Lymberakis, P. (2013), Mapping land cover gradients through analysis of hyper-temporal NDVI imagery, *International Journal of Applied Earth Observation and Geoinformation*, 23 (0), p. 301-312.
- Amarsaikhan, D., et Douglas, T. (2004), Data fusion and multisource image classification, *International Journal of Remote Sensing*, 25 (17), p. 3529-3539.
- Atkinson, P.M. (2013), Downscaling in remote sensing, *International Journal of Applied Earth Observation and Geoinformation* (0), p.
- Bagan, H., Wang, Q., Watanabe, M., Yang, Y., et Ma, J. (2005), Land cover classification from MODIS EVI times-series data using SOM neural network, *International Journal of Remote Sensing*, 26 (22), p. 4999-5012.
- Balthazar, V., Vanacker, V., et Lambin, E.F. (2012), Evaluation and parameterization of ATCOR3 topographic correction method for forest cover mapping in mountain areas, *International Journal of Applied Earth Observation and Geoinformation*, 18 (0), p. 436-450.
- Baret, F., et Guyot, G. (1991), Potentials and limits of vegetation indices for LAI and APAR assessment, *Remote Sensing of Environment*, 35 (2), p. 161-173.
- Beguiría, S., López-Moreno, J.I., et Vicente Serrano, S.M. (2007), La precipitación en el Pirineo español: diversidad espacial en las tendencias y escenarios futuros, *162*, p. 43-69.
- Bisquert, M., Bégué, A., et Deshayes, D. (2015), Object-based delineation of homogenous landscape units at regional scale based on MODIS time series, *International Journal of Applied Earth Observation and Geoinformation*, 37, p. 72-82.
- Blesius, L., et Weirich, F. (2005), The use of the Minnaert correction for land-cover classification in mountainous terrain, *International Journal of Remote Sensing*, 26 (17), p. 3831-3851.
- Boles, S.H., Xiao, X., Liu, J., Zhang, Q., Munkhtuya, S., Chen, S., et Ojima, D. (2004), Land cover characterization of Temperate East Asia using multi-temporal VEGETATION sensor data, *Remote Sensing of Environment*, 90 (4), p. 477-489.
- Boyd, D.S., et Danson, F.M. (2005), Satellite remote sensing of forest resources: three decades of research development, *Progress in Physical Geography*, 29 (1), p. 1-26.
- Boyd, D.S., et Foody, G.M. (2011), An overview of recent remote sensing and GIS based research in ecological informatics, *Ecological Informatics*, 6 (1), p. 25-36.
- Breiman, L. (2001), Random Forests, *Machine Learning*, 45 (1), p. 5-32.
- Broich, M., Stehman, S.V., Hansen, M.C., Potapov, P., et Shimabukuro, Y.E. (2009), A comparison of sampling designs for estimating deforestation from Landsat imagery: A case study of the Brazilian Legal Amazon, *Remote Sensing of Environment*, 113 (11), p. 2448-2454.
- Brown, M., Gunn, S.R., et Lewis, H.G. (1999), Support vector machines for optimal classification and spectral unmixing, *Ecological Modelling*, 120 (2-3), p. 167-179.

- Cai, H., Zhang, S., Bu, K., Yang, J., et Chang, L. (2011), Integrating geographical data and phenological characteristics derived from MODIS data for improving land cover mapping, *Journal of Geographical Sciences*, 21 (4), p. 705-718.
- Carrão, H., Gonçalves, P., et Caetano, M. (2007), Use of intra-annual satellite imagery time-series for land cover characterization purpose, *Proceedings of the 26th EARSeL Symposium*.
- Carrão, H., Gonçalves, P., et Caetano, M. (2008), Contribution of multispectral and multitemporal information from MODIS images to land cover classification, *Remote Sensing of Environment*, 112 (3), p. 986-997.
- Carvalho, L.M.T.d., Clevers, J.G.P.W., Skidmore, A.K., et Jong, S.M.d. (2004), Selection of imagery data and classifiers for mapping Brazilian semideciduous Atlantic forests, *International Journal of Applied Earth Observation and Geoinformation*, 5 (3), p. 173-186.
- Chang, C.-C., et Lin, C.-J. (2013), LIBSVM: A library for support vector machines, *ACM Trans. Intell. Syst. Technol.*, 2 (3), p. 1-27.
- Chen, D., et Stow, D. (2002), The effect of training strategies on supervised classification at different spatial resolutions, *Photogrammetric Engineering and Remote Sensing*, 68 (11), p. 1155-1162.
- Chen, J., Jönsson, P., Tamura, M., Gu, Z., Matsushita, B., et Eklundh, L. (2004), A simple method for reconstructing a high-quality NDVI time-series data set based on the Savitzky–Golay filter, *Remote Sensing of Environment*, 91 (3–4), p. 332-344.
- Chéret, V., et Denux, J.-P. (2011), Analysis of MODIS NDVI Time Series to calculate Indicators of Mediterranean Forest Fire Susceptibility, *GIScience & Remote Sensing of Environment*, 48 (2), p. 171-194.
- Chéret, V., et Denux, J.P. (2007), Mapping wildfire danger at regional scale with an index model integrating coarse spatial resolution remote sensing data, *Journal of Geophysical Research: Biogeosciences*, 112 (G2), p. n/a-n/a.
- Cihlar, J. (2000), Land cover mapping of large areas from satellites: status and research priorities, *International Journal of Remote Sensing*, 21 (6-7), p. 1093-1114.
- Cingolani, A.M., Renison, D., Zak, M.R., et Cabido, M.R. (2004), Mapping vegetation in a heterogeneous mountain rangeland using landsat data: an alternative method to define and classify land-cover units, *Remote Sensing of Environment*, 92 (1), p. 84-97.
- Clark, M.L., Aide, T.M., Grau, H.R., et Riner, G. (2010), A scalable approach to mapping annual land cover at 250 m using MODIS time series data: A case study in the Dry Chaco ecoregion of South America, *Remote Sensing of Environment*, 114 (11), p. 2816-2832.
- Cleland, E.E., Chuine, I., Menzel, A., Mooney, H.A., et Schwartz, M.D. (2007), Shifting plant phenology in response to global change, *Trends in Ecology & Evolution*, 22 (7), p. 357-365.
- Colditz, R.R., Schmidt, M., Conrad, C., Hansen, M.C., et Dech, S. (2011), Land cover classification with coarse spatial resolution data to derive continuous and discrete maps for complex regions, *Remote Sensing of Environment*, 115 (12), p. 3264-3275.
- Congalton, R.G. (1991), A review of assessing the accuracy of classifications of remotely sensed data, *Remote Sensing of Environment*, 37, p. 35-46.
- Congalton, R.G., Birch, K., Jones, R., et Schriever, J. (2002), Evaluating remotely sensed techniques for mapping riparian vegetation, *Computers and Electronics in Agriculture*, 37 (1–3), p. 113-126.
- Corcoran, J., Knight, J., et Gallant, A. (2013), Influence of Multi-Source and Multi-Temporal Remotely Sensed and Ancillary Data on the Accuracy of Random Forest Classification of Wetlands in Northern Minnesota, *Remote Sensing*, 5 (7), p. 3212.
- Cortes, C., et Vapnik, V. (1995), Support-vector networks, *Machine Learning*, 20 (3), p. 273-297.
- D'Odorico, P., Gonsamo, A., Damm, A., et Schaepman, M.E. (2013), Experimental Evaluation of Sentinel-2 Spectral Response Functions for NDVI Time-Series Continuity, *Geoscience and Remote Sensing, IEEE Transactions on*, 51 (3), p. 1336-1348.
- Dalponte, M., Bruzzone, L., et Gianelle, D. (2012), Tree species classification in the Southern Alps based on the fusion of very high geometrical resolution multispectral/hyperspectral images and LiDAR data, *Remote Sensing of Environment*, 123, p. 258-270.
- Daubet, B., De Miguel Magaña, S., et Maurette, A. (2007), Livre Blanc des forêts pyrénéennes, pour une gestion durable des Pyrénées, 83 p.

- DeFries, R., Hansen, M., et Townshend, J. (1995), Global discrimination of land cover types from metrics derived from AVHRR pathfinder data, *Remote Sensing of Environment*, 54 (3), p. 209-222.
- Delincé, J. (2002), A European Approach to Area Frame Surveys, *European Commission - Institute for Environment and Sustainability (IES)*, p.
- Dengsheng, L., Emilio, M., Guiying, L., et Scott, H. (2011), Remote Sensing Image Classification, *Advances in Environmental Remote Sensing*, CRC Press, p. 219-240.
- Dorren, L.K.A., Maier, B., et Seijmonsbergen, A.C. (2003), Improved Landsat-based forest mapping in steep mountainous terrain using object-based classification, *Forest Ecology and Management*, 183 (1-3), p. 31-46.
- Dotzler, S., Hill, J., Buddenbaum, H., et Stoffels, J. (2015), The Potential of EnMAP and Sentinel-2 Data for Detecting Drought Stress Phenomena in Deciduous Forest Communities, *Remote Sensing*, 7 (10), p. 14227.
- Drusch, M., Del Bello, U., Carlier, S., Colin, O., Fernandez, V., Gascon, F., Hoersch, B., Isola, C., Laberinti, P., Martimort, P., Meygret, A., Spoto, F., Sy, O., Marchese, F., et Bargellini, P. (2012), Sentinel-2: ESA's Optical High-Resolution Mission for GMES Operational Services, *Remote Sensing of Environment*, 120 (0), p. 25-36.
- Dymond, C.C., Mladenoff, D.J., et Radeloff, V.C. (2002), Phenological differences in Tasseled Cap indices improve deciduous forest classification, *Remote Sensing of Environment*, 80 (3), p. 460-472.
- Edwards Jr, T.C., Moisen, G.G., et Cutler, D.R. (1998), Assessing Map Accuracy in a Remotely Sensed, Ecoregion-Scale Cover Map, *Remote Sensing of Environment*, 63 (1), p. 73-83.
- Esseen, P.-A., Jansson, K.U., et Nilsson, M. (2006), Forest edge quantification by line intersect sampling in aerial photographs, *Forest Ecology and Management*, 230 (1-3), p. 32-42.
- Evans, J.P., et Geerken, R. (2006), Classifying rangeland vegetation type and coverage using a Fourier component based similarity measure, *Remote Sensing of Environment*, 105 (1), p. 1-8.
- Foody, G.M. (2002), Status of land cover classification accuracy assessment, *Remote Sensing of Environment*, 80 (1), p. 185-201.
- Foody, G.M. (2004), Thematic Map Comparison: Evaluating The Statistical Significance of Differences in Classification Accuracy, *Photogramm. Eng. Remote Sens.*, 70 (5), p. 627-633.
- Foody, G.M. (2010), Assessing the accuracy of land cover change with imperfect ground reference data, *Remote Sensing of Environment*, 114 (10), p. 2271-2285.
- Foody, G.M., et Ajay, M. (2004), A relative evaluation of multiclass image classification by support vector machines, *Geoscience and Remote Sensing, IEEE Transactions on*, 42 (6), p. 1335-1343.
- Foody, G.M., Lucas, R.M., Curran, P.J., et Honzak, M. (1997), Mapping Tropical Forest Fractional Cover from Coarse Spatial Resolution Remote Sensing Imagery, *Plant ecology*, 131 (2), p. 143-154.
- Foody, G.M., et Mathur, A. (2004), Toward intelligent training of supervised image classifications: directing training data acquisition for SVM classification, *Remote Sensing of Environment*, 93 (1-2), p. 107-117.
- Foody, G.M., et Mathur, A. (2006), The use of small training sets containing mixed pixels for accurate hard image classification: Training on mixed spectral responses for classification by a SVM, *Remote Sensing of Environment*, 103 (2), p. 179-189.
- Foody, G.M., Mathur, A., Sanchez-Hernandez, C., et Boyd, D.S. (2006), Training set size requirements for the classification of a specific class, *Remote Sensing of Environment*, 104 (1), p. 1-14.
- Forman, R.T.T., et Godron, M. (1981), Patches and Structural Components for A Landscape Ecology, *Bioscience*, 31 (10), p. 733-740.
- Forman, R.T.T., et Godron, R. (1986), *Landscape Ecology*, Wiley, 1986, 619.
- Franklin, S.E. (2001), *Remote Sensing for Sustainable Forest Management*, CRC Press, 424 p.
- Friedl, M.A., McIver, D.K., Hodges, J.C.F., Zhang, X.Y., Muchoney, D., Strahler, A.H., Woodcock, C.E., Gopal, S., Schneider, A., Cooper, A., Baccini, A., Gao, F., et Schaaf, C. (2002), Global land cover mapping from MODIS: algorithms and early results, *Remote Sensing of Environment*, 83 (1-2), p. 287-302.

- Friedl, M.A., Sulla-Menashe, D., Tan, B., Schneider, A., Ramankutty, N., Sibley, A., et Huang, X. (2010), MODIS Collection 5 global land cover: Algorithm refinements and characterization of new datasets, *Remote Sensing of Environment*, 114 (1), p. 168-182.
- Fu, P., et Rich, P.M. (2002), A geometric solar radiation model with applications in agriculture and forestry, *Computers and Electronics in Agriculture*, 37 (1-3), p. 25-35.
- Gallego, F.J., et Stibig, H.J. (2013), Area estimation from a sample of satellite images: The impact of stratification on the clustering efficiency, *International Journal of Applied Earth Observation and Geoinformation*, 22 (0), p. 139-146.
- Gao, Y., et Mas, J.F. (2008), MODIS EVI as an ancillary data for an object-based image analysis with multi-spectral MODIS data, URL: http://www.isprs.org/proceedings/XXXVIII/4-C1/.../6590_YGao_Proc_poster.pdf. (Accessed on September 07, 2011), p.
- García-Mora, T.J., Mas, J.-F., et Hinkley, E.A. (2011), Land cover mapping applications with MODIS: a literature review, *International Journal of Digital Earth*, 5 (1), p. 63-87.
- Gertner, G., Wang, G., Anderson, A.B., et Howard, H. (2007), Combining stratification and up-scaling method-block cokriging with remote sensing imagery for sampling and mapping an erosion cover factor, *Ecological Informatics*, 2 (4), p. 373-386.
- Giri, C., Pengra, B., Long, J., et Loveland, T.R. (2013), Next generation of global land cover characterization, mapping, and monitoring, *International Journal of Applied Earth Observation and Geoinformation*, 25 (0), p. 30-37.
- Gislason, P.O., Benediktsson, J.A., et Sveinsson, J.R. (2006), Random Forests for land cover classification, *Pattern Recognition Letters*, 27 (4), p. 294-300.
- Goetz, S.J., Prince, S.D., Goward, S.N., Thawley, M.M., Small, J., et Johnston, A. (1999), Mapping net primary production and related biophysical variables with remote sensing: Application to the BOREAS region, *Journal of Geophysical Research: Atmospheres*, 104 (D22), p. 27719-27734.
- Goward, S.N. (1985), North American vegetation patterns observed with the NOAA-7 Advanced Very High Resolution Radiometer, [Greenbelt, Md. :, National Aeronautics and Space Administration, Goddard Space Flight Center, p.
- Grinand, C., Rakotomalala, F., Gond, V., Vaudry, R., Bernoux, M., et Vieilledent, G. (2013), Estimating deforestation in tropical humid and dry forests in Madagascar from 2000 to 2010 using multi-date Landsat satellite images and the random forests classifier, *Remote Sensing of Environment*, 139, p. 68-80.
- Hammond, T.O., et Verbyla, D.L. (1996), Optimistic bias in classification accuracy assessment, *International Journal of Remote Sensing*, 17 (6), p. 1261-1266.
- Hansen, M.C., Defries, R.S., Townshend, J.R.G., et Sohlberg, R. (2000), Global land cover classification at 1 km spatial resolution using a classification tree approach, *International Journal of Remote Sensing*, 21 (6-7), p. 1331-1364.
- Hansen, M.C., Potapov, P.V., Moore, R., Hancher, M., Turubanova, S.A., Tyukavina, A., Thau, D., Stehman, S.V., Goetz, S.J., Loveland, T.R., Kommareddy, A., Egorov, A., Chini, L., Justice, C.O., et Townshend, J.R.G. (2013), High-Resolution Global Maps of 21st-Century Forest Cover Change, *Science*, 342 (6160), p. 850-853.
- Haralick, R.M., Shanmugam, K., et Dinstein, I.H. (1973), Textural Features for Image Classification, *Systems, Man and Cybernetics, IEEE Transactions on, SMC-3* (6), p. 610-621.
- Heiskanen, J., et Kivinen, S. (2008), Assessment of multispectral, -temporal and -angular MODIS data for tree cover mapping in the tundra-taiga transition zone, *Remote Sensing of Environment*, 112 (5), p. 2367-2380.
- Henebry, G.M. (1993), Spatial Statistics, *Ecology*, 74 (1), p. 270-270.
- Hill, M.J. (2013), Vegetation index suites as indicators of vegetation state in grassland and savanna: An analysis with simulated SENTINEL 2 data for a North American transect, *Remote Sensing of Environment*, 137 (0), p. 94-111.
- Hill, R.A., Granica, K., Smith, G.M., et Schardt, M. (2007), Representation of an alpine treeline ecotone in SPOT 5 HRG data, *Remote Sensing of Environment*, 110 (4), p. 458-467.
- Hill, R.A., Wilson, A.K., George, M., et Hinsley, S.A. (2010), Mapping tree species in temperate deciduous woodland using time-series multi-spectral data, *Applied Vegetation Science*, 13 (1), p. 86-99.

- Holben, B.N. (1986), Characteristics of maximum-value composite images from temporal AVHRR data, *International Journal of Remote Sensing*, 7 (11), p. 1417-1434.
- Hsu, C.-W., Chang, C.-C., et Lin, C.-J. (2010), A Practical Guide to Support Vector Classification, Department of Computer Science, National Taiwan University.
- Huang, C., Davis, L.S., et Townshend, J.R.G. (2002), An assessment of support vector machines for land cover classification, *International Journal of Remote Sensing*, 23 (4), p. 725-749.
- Hubert-Moy, L., Cotonnec, A., Le Du, L., Chardin, A., et Perez, P. (2001), A Comparison of Parametric Classification Procedures of Remotely Sensed Data Applied on Different Landscape Units, *Remote Sensing of Environment*, 75 (2), p. 174-187.
- Huete, A., Didan, K., Miura, T., Rodriguez, E.P., Gao, X., et Ferreira, L.G. (2002), Overview of the radiometric and biophysical performance of the MODIS vegetation indices, *Remote Sensing of Environment*, 83 (1-2), p. 195-213.
- Huete, A.R., Jackson, R.D., et Post, D.F. (1985), Spectral response of a plant canopy with different soil backgrounds, *Remote Sensing of Environment*, 17 (1), p. 37-53.
- Huete, A.R., Liu, H.Q., Batchily, K., et van Leeuwen, W. (1997), A comparison of vegetation indices over a global set of TM images for EOS-MODIS, *Remote Sensing of Environment*, 59 (3), p. 440-451.
- Hughes, G. (1968), On the mean accuracy of statistical pattern recognizers, *Information Theory*, 14 (1), p. 55-63.
- IGN (2012), La cartographie forestière de l'Inventaire Forestier National - Guide technique - version 2, 54 p.
- IGN (2014), BD Forêt version 2 - Descriptif de contenu, 17 p.
- Immitzer, M., Atzberger, C., et Koukal, T. (2012), Tree Species Classification with Random Forest Using Very High Spatial Resolution 8-Band WorldView-2 Satellite Data, *Remote Sensing*, 4 (9), p. 2661.
- Jackson, Q., et Landgrebe, D. (2001), A self-improving classifier design for high-dimensional data analysis with a limited training data set, *Geoscience and Remote Sensing Symposium, 2001. IGARSS '01. IEEE 2001 International*, 2001, 521-523 vol.1.
- Jarvis, A., Reuter, H.I., Nelson, A., et Guevara, E. (2008), Hole-filled SRTM for the globe Version 4, available from the CGIAR-CSI SRTM 90m Database (<http://srtm.csi.cgiar.org>), p.
- Jia, K., Liang, S., Wei, X., Yao, Y., Su, Y., Jiang, B., et Wang, X. (2014a), Land Cover Classification of Landsat Data with Phenological Features Extracted from Time Series MODIS NDVI Data, *Remote Sensing*, 6 (11), p. 11518-11532.
- Jia, K., Liang, S., Zhang, L., Wei, X., Yao, Y., et Xie, X. (2014b), Forest cover classification using Landsat ETM+ data and time series MODIS NDVI data, *International Journal of Applied Earth Observation and Geoinformation*, 33 (0), p. 32-38.
- Johnson, B., et Xie, Z. (2011), Unsupervised image segmentation evaluation and refinement using a multi-scale approach, *ISPRS Journal of Photogrammetry and Remote Sensing*, 66 (4), p. 473-483.
- Jönsson, P., et Eklundh, L. (2004), TIMESAT—a program for analyzing time-series of satellite sensor data, *Computers* 30 (8), p. 833-845.
- Justice, C.O., Holben, B.N., et Gwynne, M.D. (1986), Monitoring East African vegetation using AVHRR data, *International Journal of Remote Sensing*, 7 (11), p. 1453-1474.
- Justice, C.O., Townshend, J.R.G., Holben, B.N., et Tucker, C.J. (1985), Analysis of the phenology of global vegetation using meteorological satellite data, *International Journal of Remote Sensing*, 6 (8), p. 1271-1318.
- Justice, C.O., Vermote, E., Townshend, J.R.G., DeFries, R., Roy, D.P., Hall, D.K., Salomonson, V.V., Privette, J.L., Riggs, G., Strahler, A., Lucht, W., Myneni, R.B., Knyazikhin, Y., Running, S.W., Nemani, R.R., Zhengming, W., Huete, A.R., Van Leeuwen, W., Wolfe, R.E., Giglio, L., Muller, J.P., Lewis, P., et Barnsley, M.J. (1998), The Moderate Resolution Imaging Spectroradiometer (MODIS): land remote sensing for global change research, *Geoscience and Remote Sensing, IEEE Transactions on*, 36 (4), p. 1228-1249.
- Kerr, J.T., et Ostrovsky, M. (2003), From space to species: ecological applications for remote sensing, *Trends in Ecology & Evolution*, 18 (6), p. 299-305.

- Kim, D.-H., Sexton, J.O., Noojipady, P., Huang, C., Anand, A., Channan, S., Feng, M., et Townshend, J.R. (2014), Global, Landsat-based forest-cover change from 1990 to 2000, *Remote Sensing of Environment*, 155 (0), p. 178-193.
- Knight, J.F., Lunetta, R.S., Ediriwickrema, J., et Khorram, S. (2006), Regional Scale Land Cover Characterization Using MODIS-NDVI 250 m Multi-Temporal Imagery: A Phenology-Based Approach, *GIScience & Remote Sensing*, 43 (1), p. 1-23.
- Krahwinkler, P., et Rossmann, J. (2013), Tree Species Classification and Input Data Evaluation, *European Journal of Remote Sensing*, 46, p. 535-549.
- Krishna Prasad, V., Badarinath, K.V.S., et Eaturu, A. (2007), Spatial patterns of vegetation phenology metrics and related climatic controls of eight contrasting forest types in India – analysis from remote sensing datasets, *Theoretical and Applied Climatology*, 89 (1-2), p. 95-107.
- Kuemmerle, T., Radeloff, V.C., Perzanowski, K., et Hostert, P. (2006), Cross-border comparison of land cover and landscape pattern in Eastern Europe using a hybrid classification technique, *Remote Sensing of Environment*, 103 (4), p. 449-464.
- Kurtz, C. (2009), Analyse multirésolution d'images de télédétection par segmentations et classifications conjointes, Rapport de stage de MASTER recherche Informatique Fondamentale et Appliquée, Université de Strasbourg, 87 p.
- Lambert, J. (2014), Evaluation des baisses de vitalité des peuplements forestiers à parti de séries temporelles d'images satellitaires. Application aux résineux du sud du Massif Central et à la sapinière pyrénéenne., Agrosystèmes, Ecosystèmes et Environnement - Université de Toulouse, 164 p.
- Lê, S., Josse, J., et Husson, F. (2008), FactoMineR : an R package for multivariate analysis, *Journal of Statistical Software*, 25 (1), p. 1-18.
- Li, C., Wang, J., Wang, L., Hu, L., et Gong, P. (2014), Comparison of Classification Algorithms and Training Sample Sizes in Urban Land Classification with Landsat Thematic Mapper Imagery, *Remote Sensing*, 6 (2), p. 964.
- Lindner, M., Maroschek, M., Netherer, S., Kremer, A., Barbati, A., Garcia-Gonzalo, J., Seidl, R., Delzon, S., Corona, P., Kolström, M., Lexer, M.J., et Marchetti, M. (2010), Climate change impacts, adaptive capacity, and vulnerability of European forest ecosystems, *Forest Ecology and Management*, 259 (4), p. 698-709.
- Lister, T.W., Lister, A.J., et Alexander, E. (2014), Land use change monitoring in Maryland using a probabilistic sample and rapid photointerpretation, *Applied Geography*, 51 (0), p. 1-7.
- Loveland, T.R., Reed, B.C., Brown, J.F., Ohlen, D.O., Zhu, Z., Yang, L., et Merchant, J.W. (2000), Development of a global land cover characteristics database and IGBP DISCover from 1 km AVHRR data, *International Journal of Remote Sensing*, 21 (6-7), p. 1303-1330.
- Lu, D., Batistella, M., de Miranda, E.E., et Moran, E. (2008), A Comparative Study of Landsat TM and SPOT HRG Images for Vegetation Classification in the Brazilian Amazon, *Photogrammetric Engineering and Remote Sensing*, 74 (3), p. 311-321.
- Lu, D., et Weng, Q. (2004), Spectral mixture analysis of the urban landscape in Indianapolis with Landsat ETM+ imagery, Bethesda, MD, ETATS-UNIS, American Society for Photogrammetry and Remote Sensing, 10 p.
- Lu, D., et Weng, Q. (2007), A survey of image classification methods and techniques for improving classification performance, *International Journal of Remote Sensing*, 28 (5), p. 823-870.
- Morneau, F., Vallet, P., Toïgo, M., et Dalmaso, M. (2016), Les forêts mélangées, in *L'IF, la feuille de l'inventaire forestier*, IGN, 2016, 12.
- Nagendra, H. (2001), Using remote sensing to assess biodiversity, *International Journal of Remote Sensing*, 22 (12), p. 2377-2400.
- Nangendo, G., Skidmore, A.K., et van Oosten, H. (2007), Mapping East African tropical forests and woodlands — A comparison of classifiers, *ISPRS Journal of Photogrammetry and Remote Sensing*, 61 (6), p. 393-404.
- Ohmann, J.L., Gregory, M.J., et Roberts, H.M. (2014), Scale considerations for integrating forest inventory plot data and satellite image data for regional forest mapping, *Remote Sensing of Environment*, 151 (0), p. 3-15.
- OPCC, et CTP (2013), Etude sur l'adaptation au changement climatique dans les Pyrénées - Synthèse du rapport final, 51 p.

- Pal, M. (2005), Random forest classifier for remote sensing classification, *International Journal of Remote Sensing*, 26 (1), p. 217-222.
- Pal, M., et Foody, G.M. (2010), Feature Selection for Classification of Hyperspectral Data by SVM, *Geoscience and Remote Sensing, IEEE Transactions on*, 48 (5), p. 2297-2307.
- Pal, M., et Mather, P.M. (2005), Support vector machines for classification in remote sensing, *International Journal of Remote Sensing*, 26 (5), p. 1007-1011.
- Paola, J.D., et Schowengerdt, R.A. (1995), A detailed comparison of backpropagation neural network and maximum-likelihood classifiers for urban land use classification, *Geoscience and Remote Sensing, IEEE Transactions on*, 33 (4), p. 981-996.
- Pearson, K. (1901), On lines and planes of closest fit to systems of points in space, *Philosophical Magazine Series 6*, 2 (11), p. 559-572.
- Pettorelli, N., Vik, J.O., Mysterud, A., Gaillard, J.-M., Tucker, C.J., et Stenseth, N.C. (2005), Using the satellite-derived NDVI to assess ecological responses to environmental change, *Trends in Ecology 20* (9), p. 503-510.
- Pontius, R.G.J. (2000), Quantification error versus location error in comparison of categorical maps, *Photogramm. Eng. Remote Sens.*, 66 (8), p. 1011-1016.
- Powell, D.M.W. (2011), Evaluation: From Precision, Recall and F-Measure to ROC, Informedness, Markedness & Correlation, *Journal of Machine Learning Technologies* 2(1), p. 37-63.
- Price, K.P., Guo, X., et Stiles, J.M. (2002), Optimal Landsat TM band combinations and vegetation indices for discrimination of six grassland types in eastern Kansas, *International Journal of Remote Sensing*, 23 (23), p. 5031-5042.
- Puissant, A., Rougier, S., et Stumpf, A. (2014), Object-oriented mapping of urban trees using Random Forest classifiers, *International Journal of Applied Earth Observation and Geoinformation*, 26, p. 235-245.
- Qi, J., Chehbouni, A., Huete, A.R., Kerr, Y.H., et Sorooshian, S. (1994), A modified soil adjusted vegetation index, *Remote Sensing of Environment*, 48 (2), p. 119-126.
- Rameau, J.-C., Mansion, D., Dumé, G., Gauberville, C., Lecointe, A., Timbal, J., Keller, R., Bardat, J., et Bruno, E. (2008), Flore forestière française - Guide écologique illustré, Centre National de la Propriété Foncière, 2008, 6632.
- Redo, D.J., et Millington, A.C. (2011), A hybrid approach to mapping land-use modification and land-cover transition from MODIS time-series data: A case study from the Bolivian seasonal tropics, *Remote Sensing of Environment*, 115 (2), p. 353-372.
- Reed, B.C., Brown, J.F., VanderZee, D., Loveland, T.R., Merchant, J.W., et Ohlen, D.O. (1994), Measuring phenological variability from satellite imagery, *Journal of Vegetation Science*, 5 (5), p. 703-714.
- Reed, B.C., Schwartz, M.D., et Xiao, X. (2009), Remote Sensing Phenology, *Phenology of Ecosystem Processes: Applications in Global Change Research*, edited by A. Noormets, Springer New York, New York, NY, p. 231-246.
- Ren, G., Zhu, A.X., Wang, W., Xiao, W., Huang, Y., Li, G., Li, D., et Zhu, J. (2009), A hierarchical approach coupled with coarse DEM information for improving the efficiency and accuracy of forest mapping over very rugged terrains, *Forest Ecology and Management*, 258 (1), p. 26-34.
- Rich, P.M., Dubayah, R., Hetrick, W.A., et Saving, S.C. (1994), Using Viewshed models to calculate intercepted solar radiation: applications in ecology, *American Society for Photogrammetry and Remote Sensing Technical Papers*, p. 524-529.
- Rodes, I., Inglada, J., Hagolle, O., Dejoux, J.F., et Dedieu, G. (2012), Sampling strategies for unsupervised classification of multitemporal high resolution optical images over very large areas, *Geoscience and Remote Sensing Symposium (IGARSS), 2012 IEEE International*, 22-27 July 2012, 6761-6764.
- Rodriguez-Galiano, V., et Chica-Olmo, M. (2012), Land cover change analysis of a Mediterranean area in Spain using different sources of data: Multi-seasonal Landsat images, land surface temperature, digital terrain models and texture, *Applied Geography*, 35 (1-2), p. 208-218.
- Rodriguez-Galiano, V.F., Chica-Olmo, M., Abarca-Hernandez, F., Atkinson, P.M., et Jeganathan, C. (2012a), Random Forest classification of Mediterranean land cover using multi-seasonal imagery and multi-seasonal texture, *Remote Sensing of Environment*, 121 (0), p. 93-107.

- Rodriguez-Galiano, V.F., Ghimire, B., Rogan, J., Chica-Olmo, M., et Rigol-Sanchez, J.P. (2012b), An assessment of the effectiveness of a random forest classifier for land-cover classification, *ISPRS Journal of Photogrammetry and Remote Sensing*, 67, p. 93-104.
- Rouse, J.W., Haas, R.H., Schell, J.A., et Deering, D.W. (1973), Monitoring Vegetation Systems in the Great Plains with ERTS, p.
- Schneider, A. (2012), Monitoring land cover change in urban and peri-urban areas using dense time stacks of Landsat satellite data and a data mining approach, *Remote Sensing of Environment*, 124, p. 689-704.
- Scott Overton, W., et Stehman, S.V. (1993), Properties of designs for sampling continuous spatial resources from a triangular grid, *Communications in Statistics - Theory and Methods*, 22 (9), p. 251-264.
- Senf, C., Hostert, P., et van der Linden, S. (2012), Using MODIS time series and random forests classification for mapping land use in South-East Asia, *Geoscience and Remote Sensing Symposium (IGARSS), 2012 IEEE International*, 22-27 July 2012, 6733-6736.
- Sha, Z., Bai, Y., Xie, Y., Yu, M., et Zhang, L. (2008), Using a hybrid fuzzy classifier (HFC) to map typical grassland vegetation in Xilin River Basin, Inner Mongolia, China, *Int. J. Remote Sens.*, 29 (8), p. 2317-2337.
- Shannon, C.E. (1948), A Mathematical Theory of Communication, *Bell System Technical Journal*, 27 (3), p. 379-423.
- Shimada, M., Itoh, T., Motooka, T., Watanabe, M., Shiraishi, T., Thapa, R., et Lucas, R. (2014), New global forest/non-forest maps from ALOS PALSAR data (2007–2010), *Remote Sensing of Environment*, 155 (0), p. 13-31.
- Soubeyroux, J.M., Jourdain, S., Grimal, D., Espejo Gil, F., Esteban, P., et Merz, T. (2011), Global approach for inventory and applications of climate data on the Pyrenees chain, *Colloque SHF: "Eaux en montagne"*, Lyon, 16-17 march 2011, 7 pp.
- Spearman, C. (1904), "General Intelligence," Objectively Determined and Measured, *The American Journal of Psychology*, 15 (2), p. 201-292.
- Srivastava, P.K., Han, D., Rico-Ramirez, M.A., Bray, M., et Islam, T. (2012), Selection of classification techniques for land use/land cover change investigation, *Advances in Space Research*, 50 (9), p. 1250-1265.
- Stehman, S.V. (1996), Cost effective, practical sampling strategies for accuracy assessment of large area thematic maps, *Spatial Accuracy Assessment in Naturel Resources and Environmental Sciences : Second International Symposium*, 485-492.
- Stehman, S.V. (2009), Sampling designs for accuracy assessment of land cover, *International Journal of Remote Sensing*, 30 (20), p. 5243-5272.
- Stehman, S.V., et Czaplewski, R.L. (1998), Design and Analysis for Thematic Map Accuracy Assessment: Fundamental Principles, *Remote Sensing of Environment*, 64 (3), p. 331-344.
- Stehman, S.V., Hansen, M.C., Broich, M., et Potapov, P.V. (2011), Adapting a global stratified random sample for regional estimation of forest cover change derived from satellite imagery, *Remote Sensing of Environment*, 115 (2), p. 650-658.
- Strahler, A.H. (1980), The use of prior probabilities in maximum likelihood classification of remotely sensed data, *Remote Sensing of Environment*, 10 (2), p. 135-163.
- Studer, S., Stöckli, R., Appenzeller, C., et Vidale, P.L. (2007), A comparative study of satellite and ground-based phenology, *International Journal of Biometeorology*, 51 (5), p. 405-414.
- Sulla-Menashe, D., Friedl, M.A., Krankina, O.N., Baccini, A., Woodcock, C.E., Sibley, A., Sun, G., Kharuk, V., et Elsakov, V. (2011), Hierarchical mapping of Northern Eurasian land cover using MODIS data, *Remote Sensing of Environment*, 115 (2), p. 392-403.
- Thompson, I.D., Maher, S.C., Rouillard, D.P., Fryxell, J.M., et Baker, J.A. (2007), Accuracy of forest inventory mapping: Some implications for boreal forest management, *Forest Ecology and Management*, 252 (1–3), p. 208-221.
- Toomey, M., et Vierling, L.A. (2005), Multispectral remote sensing of landscape level foliar moisture: techniques and applications for forest ecosystem monitoring, *Canadian Journal of Forest Research*, 35 (5), p. 1087-1097.
- Townshend, J.R.G., Justice, C.O., Skole, D., Malingreau, J.P., Cihlar, J., Teillet, P., Sadowski, F., et Ruttnerberg, S. (1994), The 1 km resolution global data set: needs of the International

- Geosphere Biosphere Programme, *International Journal of Remote Sensing*, 15 (17), p. 3417-3441.
- Tso, B., et Mather, P.M. (2009), Classification Methods for Remotely Sensed Data, Second Edition, CRC Press, 183-220 p.
- Tucker, C.J., et Sellers, P.J. (1986), Satellite remote sensing of primary production, *International Journal of Remote Sensing*, 7 (11), p. 1395-1416.
- Tucker, C.J., Townshend, J.R.G., et Goff, T.E. (1985), African Land-Cover Classification Using Satellite Data, *Science*, 227 (4685), p. 369-375.
- Turner, M.G. (1989), Landscape Ecology: The Effect of Pattern on Process, *Annual Review of Ecology and Systematics*, 20 (1), p. 171-197.
- Turner, M.G. (1990), Spatial and temporal analysis of landscape patterns, *Landscape Ecology*, 4 (1), p. 21-30.
- Vintrou, E., Desbrosse, A., Bégué, A., Traoré, S., Baron, C., et Lo Seen, D. (2012), Crop area mapping in West Africa using landscape stratification of MODIS time series and comparison with existing global land products, *International Journal of Applied Earth Observation and Geoinformation*, 14 (1), p. 83-93.
- Wang, J., Zhao, Y., Li, C., Yu, L., Liu, D., et Gong, P. (2014), Mapping global land cover in 2001 and 2010 with spatial-temporal consistency at 250 m resolution, *ISPRS Journal of Photogrammetry and Remote Sensing* (0), p.
- Welch, R., Madden, M., et Jordan, T. (2002), Photogrammetric and GIS techniques for the development of vegetation databases of mountainous areas: Great Smoky Mountains National Park, *ISPRS Journal of Photogrammetry and Remote Sensing*, 57 (1-2), p. 53-68.
- Westoby, J.C. (1989), Introduction to world Forestry : people and their trees, Oxford, UK, B. Blackwell, p.
- Woodcock, C., et Harward, V.J. (1992), Nested-hierarchical scene models and image segmentation, *International Journal of Remote Sensing*, 13 (16), p. 3167-3187.
- Xie, Y., Sha, Z., et Yu, M. (2008), Remote sensing imagery in vegetation mapping: a review, *Journal of Plant Ecology*, 1 (1), p. 9-23.
- Zhang, X., Friedl, M.A., et Schaaf, C.B. (2006), Global vegetation phenology from Moderate Resolution Imaging Spectroradiometer (MODIS): Evaluation of global patterns and comparison with in situ measurements, *Journal of Geophysical Research: Biogeosciences*, 111 (G4), p. 1-14.
- Zhang, X., Sun, R., Zhang, B., et Tong, Q. (2008), Land cover classification of the North China Plain using MODIS_EVI time series, *ISPRS Journal of Photogrammetry and Remote Sensing*, 63 (4), p. 476-484.
- Zhang, X., Xiao, P., et Feng, X. (2012), An Unsupervised Evaluation Method for Remotely Sensed Imagery Segmentation, *Geoscience and Remote Sensing Letters, IEEE*, 9 (2), p. 156-160.
- Zhang, Y. (2004), Understanding image fusion, *Photogrammetric Engineering & Remote Sensing*, 70 (6), p. 657-661.
- Zhang, Y., Gao, J., et Wang, J. (2007), Detailed mapping of a salt farm from Landsat TM imagery using neural network and maximum likelihood classifiers: a comparison, *International Journal of Remote Sensing*, 28 (10), p. 2077-2089.
- Zhou, L., Kaufmann, R.K., Tian, Y., Myneni, R.B., et Tucker, C.J. (2003), Relation between interannual variations in satellite measures of northern forest greenness and climate between 1982 and 1999, *Journal of Geophysical Research: Atmospheres*, 108 (D1), p. 4004.
- Zhu, L., et Tateishi, R. (2006), Fusion of multisensor multitemporal satellite data for land cover mapping, *International Journal of Remote Sensing*, 27 (5), p. 903-918.
- Zhu, X., et Liu, D. (2014), Accurate mapping of forest types using dense seasonal Landsat time-series, *ISPRS Journal of Photogrammetry and Remote Sensing*, 96 (0), p. 1-11.

Résumé : La cartographie du couvert végétal est un outil essentiel au suivi et à la gestion des milieux « naturels ». Des cartes caractérisant les essences forestières à l'échelle régionale sont nécessaires pour la gestion des milieux forestiers. Les séries temporelles d'images satellitaires optiques à moyenne résolution spatiale, peuvent permettre de satisfaire ce besoin. L'objectif de cette thèse est d'améliorer la classification supervisée d'une série temporelle afin de produire des cartes à l'échelle régionale détaillant la composition en essences de la végétation forestière. Nous avons d'abord évalué l'apport de la stratification du site d'étude pour améliorer les résultats de la classification d'une série temporelle d'images MODIS. Le recours à une stratification à partir d'une segmentation orientée objet améliore la classification supervisée, avec une augmentation de la valeur de Kappa et du taux de rejet des pixels à classer. Un seuil minimal et un seuil maximal de la surface de végétation à classer ont été identifiés, correspondant respectivement à un taux de rejet trop élevé et à une absence d'effet de la stratification. Nous avons ensuite évalué l'influence de l'organisation de la série temporelle d'images à moyenne résolution spatiale et du choix de l'algorithme de classification. Cette évaluation a été effectuée pour trois algorithmes (maximum de vraisemblance, Support Vector Machine, Random Forest) en faisant varier les caractéristiques de la série temporelle. On observe un effet de la temporalité et de la radiométrie sur la précision de la classification particulièrement significatif et la supériorité de l'algorithme Random Forest. Sur le plan thématique, des confusions subsistent et certains mélanges d'essences sont mal distingués. Nous avons alors cherché à évaluer l'apport du changement de résolution spatiale des images composant la série temporelle pour améliorer les résultats de classification. Les conclusions effectuées précédemment avec les données MODIS sont confortées, ce qui permet de conclure qu'elles sont indépendantes des données d'entrée et de leur résolution spatiale. Une amélioration significative est apportée par le changement de résolution spatiale, avec une augmentation de l'indice de Kappa de 0,60 à 0,72 obtenue grâce à la diminution de la proportion de pixels mixtes. Quelle que soit la résolution spatiale des images utilisées, les résultats obtenus montrent que la définition d'une procédure optimale améliore sensiblement les résultats de la classification.

Mots clefs : télédétection, séries temporelles, formations forestières, images MODIS, classification supervisée.

Abstract : Forest cover mapping is an essential tool for forest management. Detailed maps, characterizing forest types at a regional scale, are needed. This need can be fulfilled by medium spatial resolution optical satellite images time series. This thesis aims at improving the supervised classification procedure applied to a time series, to produce maps detailing forest types at a regional scale. To meet this goal, the improvement of the results obtained by the classification of a MODIS time series, performed with a stratification of the study area, was assessed. An improvement of classification accuracy due to stratification built by object-based image analysis was observed, with an increase of the Kappa index value and an increase of the reject fraction rate. These two phenomena are correlated to the classified vegetation area. A minimal and a maximal value were identified, respectively related to a too high reject fraction rate and a neutral stratification impact. We carried out a second study, aiming at assessing the influence of the medium spatial resolution time series organization and of the algorithm on classification quality. Three distinct classification algorithms (maximum likelihood, Support Vector Machine, Random Forest) and several time series were studied. A significant improvement due to temporal and radiometric effects and the superiority of Random Forest were highlighted by the results. Thematic confusions and low user's and producer's accuracies were still observed for several classes. We finally studied the improvement brought by a spatial resolution change for the images composing the time series to discriminate classes of mixed forest species. The conclusions of the former study (MODIS images) were confirmed with DEIMOS images. We can conclude that these effects are independent from input data and their spatial resolution. A significant improvement was also observed with an increase of the Kappa index value from 0,60 with MODIS data to 0,72 with DEIMOS data, due to a decrease of the mixed pixels rate.

Key words : remote sensing, time series, forest types, MODIS images, supervised classification.