



**HAL**  
open science

# Exploitation de séries temporelles d'images satellites à haute résolution spatiale pour le suivi des prairies en milieu agricole

Pauline Dusseux

► **To cite this version:**

Pauline Dusseux. Exploitation de séries temporelles d'images satellites à haute résolution spatiale pour le suivi des prairies en milieu agricole. Géographie. Université Rennes 2, 2014. Français. NNT : 2014REN20031 . tel-01131770

**HAL Id: tel-01131770**

**<https://theses.hal.science/tel-01131770>**

Submitted on 16 Mar 2015

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

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



**THESE / UNIVERSITE RENNES 2 HAUTE-BRETAGNE**

sous le sceau de l'Université européenne de Bretagne

pour obtenir le titre de

**DOCTEUR DE L'UNIVERSITE EUROPEENNE DE BRETAGNE**

Mention : Géographie

**Ecole doctorale Sciences Humaines et Sociales**

présentée par

**Pauline DUSSEUX**

Préparée à l'Unité Mixte de Recherche 6554 CNRS  
LETG Rennes COSTEL

Université Rennes 2 Haute-Bretagne

# Exploitation de séries temporelles d'images satellites à haute résolution spatiale pour le suivi des prairies en milieu agricole

**Thèse soutenue le 05 décembre 2014**

devant le jury composé de :

**Agnès Bégué**

Chargé de Recherche HDR - Cirad Montpellier / *rapporteur*

**Martine Guérif**

Directrice de Recherche - INRA Avignon / *rapporteur*

**Catherine Méring**

Professeur - Université Paris Diderot-Paris 7 / *examineur*

**Heather McNairn**

Chercheur - Ottawa / *examineur*

**Thomas Corpetti**

Directeur de Recherche - CNRS / *Co-directeur de thèse*

**Laurence Hubert-Moy**

Professeur - Université Rennes 2 Haute-Bretagne / *Directrice de thèse*







## Remerciements

---

---

Je tiens à remercier toutes les personnes qui, directement ou indirectement, ont contribué à l'aboutissement de cette thèse, et qui, de près ou de loin, m'ont entourée, soutenue et encouragée durant ces années.

Mes remerciements s'adressent d'abord à mes deux directeurs de thèse, Laurence Hubert-Moy et Thomas Corpetti. Je les remercie d'avoir accepté d'encadrer ce travail de doctorat, de m'avoir fait confiance et de m'avoir soutenue durant ces quatre années.

Laurence, je vous remercie d'avoir dirigé cette thèse et des conseils apportés qui ont été nombreux et importants. Travailler avec vous m'a permis d'apprendre beaucoup et je tiens notamment à vous remercier pour l'intérêt que vous avez porté à la valorisation de mes travaux de thèse que ce soit dans des revues scientifiques ou pour des colloques nationaux et internationaux. J'ai ainsi eu la chance de voyager et de pouvoir présenter mes travaux à plusieurs reprises durant le doctorat et de rencontrer des personnes de divers horizons.

Thomas, je te remercie d'avoir co-encadré cette thèse. Travailler avec toi m'a tout d'abord permis d'acquérir de nouvelles compétences pour avancer dans mon travail de thèse. Et grâce à ta collaboration avec le laboratoire LIAMA à Pékin j'ai eu la chance de passer six mois pendant mon doctorat en Chine dans l'équipe TIPE, ce qui a été une expérience très enrichissante. J'ai ainsi pu rencontrer de nouvelles personnes et travailler avec des gens de différentes équipes de recherche, ceci également grâce à ta collaboration avec l'équipe OBELIX de l'IRISA de Vannes.

Je remercie Agnès Bégué, Martine Guérif, Catherine Méring et Heather McNairn d'avoir accepté de participer à mon jury de thèse et d'évaluer mon travail.

Je tiens aussi à remercier Samuel Corgne pour qui Idrisi n'a plus aucun secret... et avec qui j'ai réalisé ma première classification ! Tu m'as aussi permis de réaliser mon tout premier stage au laboratoire COSTEL en 2007 ce qui m'a finalement amenée jusqu'au doctorat... Et en plus de l'initiation à l'optique, je souhaiterais te remercier de m'avoir initiée au radar (et presque même convaincue).

Je souhaite remercier très fortement Rémi Lecerf pour son aide et ses conseils sur l'utilisation du modèle de transfert radiatif PROSPECT-SAIL.

Durant ce travail de thèse, j'ai aussi été amenée à travailler et échanger avec des chercheurs attachés à d'autres laboratoires notamment dans le cadre du programme ACASSYA. Ainsi, je tiens à remercier Françoise Vertès (INRA) avec qui j'ai beaucoup appris sur les prairies. Je souhaite aussi la remercier pour ses relectures attentives et constructives des valorisations qu'on a réalisées ensemble. Je tiens à remercier Marie-Odile Cordier et Yulong Zhao (IRISA, INRIA) d'avoir accepté notre participation pour le paramétrage du modèle Pa-

turMata. Je souhaite aussi remercier Laurent Ruiz et Chantal Gascuel, les deux coordinateurs du programme ACASSYA pour l'intérêt qu'ils ont porté à notre travail.

Je tiens aussi à remercier les membres de l'équipe OBELIX de l'IRISA Vannes pour leur accueil et les échanges scientifiques qui ont pu être réalisés. Je remercie aussi Xing Gong pour sa participation et son aide par rapport au développement des méthodes de classification qui ont été testées dans cette thèse.

Je souhaite très fortement remercier toutes les personnes qui m'ont accompagnée sur le célèbre Yaristan, zone d'étude bien connue pour sa gastronomie, ses cultures de phacélie et autres curiosités... (cols à 2500m, crocodiles, ..., voir avec Olivier pour leurs localisations). Plus particulièrement, je remercie le 'Chef' Samuel, pour qui, après Idrisi, le Yar n'a plus de secret et Maxime Vitter pour leur présence quasi mensuelle sur les routes du Yar et à la table du Capri ! Je remercie aussi Jean Nabucet pour l'initiation au matériel de terrain et à la reconnaissance des cultures. Et oui, grâce à toi je sais maintenant comment reconnaître une avoine d'une prairie à peine sortie de terre... Je souhaite remercier aussi les copines (Gwen et Adeline), Xavier et Arnaud pour les coups de main en période creuse de main d'œuvre... ça a été un plaisir de partager avec vous tous ces moments contribuant très fortement à l'aboutissement de mon travail de thèse.

Je tiens à remercier tous les membres du laboratoire COSTEL pour leur accueil, leur sympathie et tous les moments partagés autour d'un repas, d'un verre, ..., ou au détour d'un couloir : merci à la direction, aux personnels administratifs, aux ingénieurs, aux chercheurs et aux enseignants-chercheurs.

Plus particulièrement, je tiens à remercier Valérie et Johan pour l'aide apportée pour la préparation des cours et je remercie d'autant plus Johan pour le soutien et la relecture du manuscrit.

Je tiens aussi à remercier très sincèrement Jean pour sa présence dans les bons comme dans les mauvais moments, pour sa disponibilité, et pour toutes ses explications que ce soit à propos de modelbuilder, de homebuilder ou de furniturebuilder, ..., Jean pour tous, tous pour Jean !

Je remercie bien évidemment tous les doctorants, post-docs et stagiaires qui ont occupé le « bureau des gens qui bossent » et même ceux du « bureau des mecs cool » avec qui j'ai partagé mon quotidien : Edwige, Étienne, Fernanda, Héloïsa, Igor, Julie, Karel, Marianne, Mercedes, Pascal, Perrine, Pierre, Renan, Solen, Véronique et Xing Gong, merci pour vos encouragements et tous les moments passés ensemble. Je remercie aussi particulièrement les *Docteurs* Bonnefoy, Bourget, Delahaye, Lefebvre, Rapinel et Vannier pour leur soutien et les précieux conseils prodigués au cours de ces années.

Je souhaite remercier toutes les personnes que j'ai pu rencontrer lors de mon séjour en Chine et qui m'ont permis de ne pas me sentir trop seule dans cette ville tellement gigantesque et avec qui j'ai partagé de très bons moments : Nicolas C., Nicolas C., Jean-Baptiste et Ling, Pascal, Gong Xing, Cyril, Antoine et merci à Thomas pour son accueil.

Je souhaite remercier tous les organismes qui ont participé au financement de ce doctorat : le CNRS, le projet ANR ACASSYA, l'école doctorale SHS, le laboratoire COSTEL, la région Bretagne et Rennes Métropole.

Je remercie aussi les amis qui, même à distance, ont toujours les bons mots pour remonter le moral, apporter leur soutien et communiquer leur bonne humeur. Merci à Mathilde, Anne-Solène, Rémy, Guillaume, Tanguy, Pierre-Louis et Julie.

Merci aux copines de géographie (et aux nombreuses heures passées dans le centre de Rennes ;) ) : Gwen (mention spéciale pour le soutien et les mots d'encouragement quasi quotidien, merci gtalk!), Adeline, Binta, Fanny, Camille et Marion et merci à Maxime avec qui j'ai partagé les années du Master TASE, les stages au COSTEL et un bureau!

Je remercie aussi Sébastien et Stéphanie et Jean et Émilie pour l'initiation aux jeux de société et les nombreuses parties qui ont suivi ;).

Mes remerciements les plus chaleureux s'adressent à mes parents et à mon frère qui m'ont toujours soutenue dans ce projet. L'intérêt que vous avez porté à mon travail a été très important pour moi. Vous m'avez toujours fait confiance et suivi dans mes choix et pour ça je vous en suis très reconnaissante. Je remercie mes grands-mères pour leur présence et les bons petits plats mijotés du dimanche. Je tiens aussi à remercier Odile, Bernard, Damien et Paola pour leur soutien et leurs encouragements durant ces années.

Enfin, un grand merci à la personne qui m'a supportée et soutenue dans cette aventure, et avec qui « I've been everywhere, man. I've been everywhere, man. Crossed the desert's bare, man. I've breathed the mountain air, man. Of travel I've had my share, man. I've been everywhere, man. I've been to : ... ».





# Sommaire

Introduction Générale . . . . .	xi
<b>1 Identification, caractérisation et suivi des prairies par télédétection</b>	<b>1</b>
1.1 Éléments de contexte . . . . .	3
1.1.1 Problématiques et enjeux de l'étude des prairies en milieu agricole . . .	3
1.1.2 Les prairies en milieu agricole : caractéristiques et modes de gestion . .	4
1.2 La télédétection : potentiel pour le suivi des prairies en milieu agricole . . . .	11
1.2.1 Caractéristiques des données de télédétection utilisables pour l'étude des prairies . . . . .	11
1.2.2 Télédétection et prairies : état de l'art . . . . .	18
1.2.3 Classification de séries temporelles de données de télédétection . . . . .	29
1.3 Le site d'étude . . . . .	35
1.3.1 Caractéristiques du bassin versant du Yar . . . . .	35
1.3.2 Historique de l'occupation des sols sur le bassin versant du Yar pour déterminer la place des prairies dans les systèmes de production . . . .	37
1.4 Les données et leur traitement . . . . .	47
1.4.1 Les données de télédétection . . . . .	47
1.4.2 Les observations et mesures terrain . . . . .	56
Synthèse et conclusion du premier chapitre . . . . .	63
<b>2 Du terrain à l'image : Quels paramètres dérivés des séries temporelles d'images de télédétection optiques sont les plus adaptés à l'étude des prai- ries ?</b>	<b>65</b>
Introduction . . . . .	67
2.1 Évaluation de paramètres dérivés d'une série temporelle optique à haute réso- lution spatiale pour estimer la biomasse des prairies . . . . .	69
2.1.1 Introduction . . . . .	71
2.1.2 Méthodologie . . . . .	71
2.1.3 Résultats et discussion . . . . .	73
2.1.4 Conclusion . . . . .	76
2.2 Évaluation de paramètres dérivés d'une série temporelle optique à haute réso- lution spatiale pour discriminer des pratiques agricoles sur des prairies . . . .	77
2.2.1 Introduction . . . . .	79
2.2.2 Méthodologie . . . . .	79
2.2.3 Résultats et discussion . . . . .	82

2.2.4 Conclusion . . . . .	94
Synthèse et conclusion du second chapitre . . . . .	95
<b>3 Exploitation de séries temporelles d’images satellites à haute résolution spatiale pour l’identification des prairies</b>	<b>97</b>
Introduction . . . . .	99
3.1 Analyse de séries temporelles d’images optiques à haute résolution spatiale pour l’identification des prairies . . . . .	101
3.1.1 Introduction . . . . .	103
3.1.2 Méthodologie . . . . .	103
3.1.3 Résultats . . . . .	104
3.1.4 Conclusion . . . . .	110
3.2 L’apport de séries temporelles d’images radars pour l’identification des prairies	111
3.2.1 Classification d’une série temporelle d’images optiques SPOT 5 et Landsat et d’une série temporelle d’images Radarsat–2 en mode « Quad-pol »	113
3.2.2 Classification d’une série temporelle d’images optiques SPOT 4 et d’une série temporelle d’images Radarsat-2 en mode « Ultra-fin » . . . . .	129
Synthèse et conclusion du troisième chapitre . . . . .	137
<b>4 Exploitation de séries temporelles d’images satellites à haute résolution spatiale pour l’identification des modes de gestion des prairies</b>	<b>139</b>
Introduction . . . . .	141
4.1 Comparaison de méthodes de classification pour identifier les modes de gestion des prairies . . . . .	143
4.1.1 Introduction . . . . .	145
4.1.2 Méthodologie . . . . .	145
4.1.3 Résultats . . . . .	149
4.1.4 Conclusion . . . . .	153
4.2 Comparaison inter-annuelle de séries temporelles d’images optiques et/ou radars pour identifier les modes de gestion des prairies . . . . .	155
4.2.1 Introduction . . . . .	157
4.2.2 Méthodologie . . . . .	157
4.2.3 Résultats . . . . .	158
4.2.4 Conclusion . . . . .	164
Synthèse et conclusion du quatrième chapitre . . . . .	165
<b>Conclusion Générale</b>	<b>167</b>
<b>Bibliographie</b>	<b>171</b>
<b>A Annexe 1</b>	<b>191</b>
<b>B Annexe 2</b>	<b>209</b>
<b>C Annexe 3</b>	<b>231</b>

## Introduction Générale

---

Les prairies, qui recouvrent une grande diversité, occupent aujourd’hui environ 40% des surfaces terrestres. En Europe, les prairies permanentes et temporaires couvraient encore respectivement 33% et 6% du total de la Surface Agricole Utile (SAU) en 2007 [Huyghe *et al.* 2014]. Cependant, une diminution des surfaces en prairies, au détriment des cultures, des surfaces boisées et dans une moindre mesure des surfaces urbanisées, est observée depuis plusieurs décennies [Wright & Wimberly 2013]. Dans le contexte de l’intensification de l’agriculture, cette baisse s’est accompagnée de changements dans leurs modes de gestion, telles qu’une hausse de la fréquence de leur retournement ou une augmentation de leur fertilisation.

Or, les couverts prairiaux ont des fonctions multiples. Ils jouent un rôle important tant sur le plan économique dans les systèmes fourragers que sur le plan environnemental dans la régulation des flux d’azote, de polluants et de carbone. La diminution des prairies et les changements qui sont intervenus dans leur mode de gestion affectent les systèmes environnementaux de différentes façons, allant de l’augmentation de la pollution de l’eau, la dégradation des sols ou la baisse de la biodiversité [Sullivan *et al.* 2010, Klimek *et al.* 2007]. Ainsi, le rôle fonctionnel des prairies varie avec les pratiques mises en place par les agriculteurs, telles que les modalités de pâturage et/ou fauche et de fertilisation [Vertès *et al.* 2007].

L’identification des prairies et de leurs modes de gestion apparaît donc essentielle pour évaluer leur place dans les systèmes agricoles actuels et mesurer l’impact de leurs modes de gestion sur l’environnement. Plus précisément, et au regard des conséquences des pratiques effectuées sur les prairies et de leur rôle dans les systèmes de production basés sur l’élevage, le suivi régulier des prairies représente donc un enjeu important : (i) à l’échelle inter-annuelle pour déterminer la localisation, la durée des prairies et la fréquence de leur retournement et (ii) à l’échelle intra-annuelle pour identifier les pratiques agricoles qui leur sont associées.

Or, actuellement, les inventaires et le suivi des prairies en milieu agricole sont très partiels [García-Feced *et al.* 2014] et la répartition spatio-temporelle de leurs modes de gestion est *a fortiori* encore plus méconnue [Hill *et al.* 2005] dans la mesure où les modes de gestion des prairies varient en fonction de la configuration des exploitations agricoles (système d’exploitation, surface, situation géographique de la parcelle vis-à-vis du siège d’exploitation), des besoins de l’agriculteur et du climat. Afin de pouvoir étudier les relations entre les systèmes agricoles et les risques liés à l’environnement, la cartographie des prairies doit être réalisée à l’échelle parcellaire, mais analysée à l’échelle de l’exploitation agricole qui est l’échelle de la gestion des pratiques, et à des échelles plus larges telles que celles du bassin versant ou de la région qui sont les échelles auxquelles les impacts de ces pratiques se mesurent.

Quand ces pratiques sont observées sur le terrain ou à partir de l'interprétation de photographies aériennes, leur inventaire et leur suivi peuvent être très précis mais ils sont le plus souvent limités à quelques parcelles, voire au mieux à quelques exploitations agricoles [Delaby *et al.* 2001]. Quand ils sont réalisés avec des données issues des recensements agricoles, ils peuvent couvrir le territoire national, mais l'inventaire des prairies est incomplet et les pratiques associées à ces prairies ne sont pas répertoriées [Lecerf 2008]. En conséquence, les modèles utilisés pour comprendre le fonctionnement des systèmes agricoles incluant des prairies, pour simuler leur évolution future et évaluer leur impact sur l'environnement sont limités à utiliser des informations qui ne sont pas représentatives de la diversité réelle des pratiques rencontrées en réalité et simulent des pratiques sans connaître leur fréquence et leur répartition spatiale sur des territoires étendus. Pour connaître précisément les dynamiques spatio-temporelles des prairies et des pratiques agricoles effectuées sur celles-ci à des échelles territoriales, il est nécessaire d'avoir recours à des données acquises par télédétection.

La télédétection, qui permet d'étudier l'état et l'évolution des surfaces terrestres, peut être envisagée pour répondre à cet enjeu. Elle permet de suivre et d'étudier les systèmes agricoles mis en place sur des territoires plus ou moins étendus en fonction des données utilisées et ainsi de comprendre les dynamiques agricoles (changements d'occupation et d'utilisation des sols) qui en découlent à l'échelle d'une exploitation, d'un bassin versant, d'une région voire d'un pays tout entier [Atzberger 2013, Vanden Borre *et al.* 2011, Lambin & Linderman 2006]. Toutefois, jusqu'à présent, l'étude des prairies par télédétection se heurtait à deux difficultés : 1- la faible capacité de revisite des capteurs à haute résolution spatiale qui permettent d'identifier les contours des parcelles agricoles [Benoit *et al.* 1989, Girard & Benoit 1990] mais sans pouvoir toujours identifier les prairies et rarement les caractériser (confusion avec les autres cultures selon le stade de croissance, le développement de la végétation, ...) et 2- la faible précision spatiale des capteurs à moyenne résolution, qui mettent en évidence des évolutions d'îlots parcellaires grâce à leur forte répétitivité [Lecerf 2008] mais sans pouvoir localiser précisément les parcelles de prairies et les caractériser. En outre, étant données la diversité spatiale et structurelle et les compositions très diverses des prairies, des données acquises à hautes résolutions spatiale et temporelle sont nécessaires pour les étudier [Feilhauer *et al.* 2013, Franke *et al.* 2012, Foerster *et al.* 2012, Schuster *et al.* 2011, Hill *et al.* 2005, Mehner *et al.* 2004]. Les techniques d'observation spatiale ont beaucoup progressé ces dernières années et la disponibilité de séries temporelles d'images à haute résolution spatiale, à travers la multiplication des capteurs à haute résolution spatiale d'une part, et la conception programmée de capteurs à haute résolution spatiale et à forte capacité de revisite d'autre part, ouvre de nouvelles perspectives pour l'étude des prairies à des échelles fines. Ainsi, la disponibilité de séries temporelles d'images satellites constituées aujourd'hui à partir de données acquises par plusieurs capteurs et bientôt avec un seul (Ven $\mu$ s, Sentinel-2) permet désormais d'envisager l'identification précise des prairies et des modes de gestion qui leur sont associés [Hill 2013, Richter *et al.* 2012]. Elle pose aussi la question de l'approche méthodologique à adopter pour traiter ces séries temporelles d'images.

La végétation peut être étudiée à partir de séries temporelles d'images satellites optiques et/ou radars à haute résolution spatiale à travers l'estimation de paramètres décrivant la surface terrestre (indices de végétation, variables biophysiques, paramètres polarimétriques, ...). Les potentialités de l'imagerie optique et radar pour le suivi de la végétation ont déjà été exploitées pour des applications agricoles et ont montré leur intérêt pour étudier et suivre le développement des plantes et identifier les différentes pratiques culturales [Homolová *et al.* 2013, Liu *et al.* 2013, Yang *et al.* 2011, Smith & Buckley 2011, El Hajj *et al.* 2009, Baghdadadi *et al.* 2009, Hill *et al.* 2005, Blaes *et al.* 2005, McNairn & Brisco 2004, Hill 2004, Price *et al.* 2002]. Toutefois, ces séries n'ont pas encore été évaluées pour effectuer le suivi de couverts prairiaux à l'échelle parcellaire. Or, la diversité des prairies et de leur mode de gestion est telle que leur reconnaissance à partir de ces séries temporelles posent un problème méthodologique, tant en termes de choix de paramètre pertinent pour identifier les prairies et leurs modes de gestion, qu'en termes de choix de méthodes de classification de ces séries de paramètres.

**L'objectif principal de cette thèse est d'identifier les prairies et de déterminer leurs modes de gestion à partir de séries temporelles d'images de télédétection à haute résolution spatiale.** Il peut se décliner en un objectif thématique, qui est l'estimation de la place et de la gestion des prairies dans les systèmes de production, et en un objectif méthodologique, qui est l'évaluation et la classification de variables dérivées de séries temporelles d'images de télédétection à haute résolution spatiale pour discriminer différents types de prairies et déterminer leur mode de gestion.

Cette thèse s'inscrit dans le contexte de la préparation des futures missions spatiales d'observation de la terre *Venus* et *Sentinel* qui produiront des séries temporelles d'images à hautes résolutions spatiale et temporelle.

Cette thèse est structurée en quatre chapitres (Figure 1) :

- Le premier chapitre développe la problématique et dresse un état des données et des méthodes permettant d'étudier les prairies et leurs modes de gestion à l'aide de séries temporelles d'images satellites. L'objectif est de mettre en évidence l'ensemble des enjeux liés à l'identification et à la caractérisation des prairies et de montrer l'importance d'un suivi intra-annuel des couverts prairiaux à une échelle parcellaire. Un bilan des méthodes permettant de suivre les couverts prairiaux à l'aide de séries temporelles d'images satellites est exposé, avant la présentation du site d'étude ainsi que des données et de leur traitement. Ce dernier consiste à produire les paramètres dont l'utilisation est présentée dans les chapitres suivants.
- Le second chapitre porte sur l'évaluation des paramètres dérivés des images satellites pour identifier et caractériser les prairies. Il comprend deux parties : la première vise à déterminer le ou les paramètre(s) le(s) plus adapté(s) pour estimer la biomasse, tandis que la seconde a pour objectif de d'évaluer les même paramètres pour identifier trois

types de pratiques agricoles associées aux prairies, c'est-à-dire le pâturage, la fauche et l'exploitation mixte de ces deux pratiques.

- Le troisième chapitre est focalisé sur l'évaluation de séries temporelles d'images satellites à haute résolution spatiale pour identifier les prairies à l'échelle parcellaire sur l'ensemble d'un bassin versant en les discriminant des cultures. Dans ce chapitre, les séries temporelles utilisées sont constituées du paramètre déterminé comme étant le plus pertinent pour cela dans le chapitre précédent. Dans un premier temps, seules des séries d'images optiques sont exploitées, tandis que la synergie entre des séries d'images optiques et radars est évaluée dans un second temps.
- Le dernier et quatrième chapitre porte sur l'évaluation de séries temporelles d'images satellites à haute résolution spatiale pour identifier des modes de gestion réalisés sur les parcelles de prairies. La question de la classification des profils temporels de paramètres dérivés d'images satellites à haute résolution spatiale est traitée ici à travers la comparaison de plusieurs méthodes de classification. Ces méthodes sont appliquées dans un premier temps sur une série d'images optiques, puis dans un deuxième temps sur deux séries d'images optiques et deux séries d'images radars afin d'une part de valider les résultats obtenus précédemment avec une série d'images optiques, et d'autre part d'évaluer les images radars pour identifier les modes de gestion des prairies.

*Cette thèse a été effectuée dans le cadre du projet ACASSYA (ACcompagner l'évolution Agro-écologique deS SYstèmes d'élevAge dans les bassins versants côtiers), programme ANR SYSTERRA (Écosystèmes, Territoires, Ressources vivantes et Agricultures). Elle s'inscrit dans l'axe 2 du projet intitulé « Modélisation agro-écologique des élevages d'un bassin versant, intégrant les contraintes des systèmes d'élevage et les structures du milieu et des paysages » qui vise à élaborer un outil de simulation du fonctionnement des agro-écosystèmes à l'échelle du bassin versant, en prenant en compte son fonctionnement biophysique, ses structures de paysages et les contraintes des exploitations agricoles. L'étude de la répartition spatiale des systèmes de culture dans le paysage et plus particulièrement l'identification et la caractérisation des prairies est inscrite dans la tâche 3 de l'axe 2 qui s'intitule « Répartition des cultures dans le paysage et gestion des prairies ». Ces recherches ont été menées conjointement par plusieurs équipes (UMR 1069 SAS INRA Rennes-Quimper, UMR Production du Lait INRA, LETG Rennes COSTEL UMR CNRS 6554, UMR CNRS 7618 Biogéochimie et écologie des milieux continentaux, IRISA Rennes 1) dans un cadre pluridisciplinaire impliquant des agronomes, des géographes et des modélisateurs.*

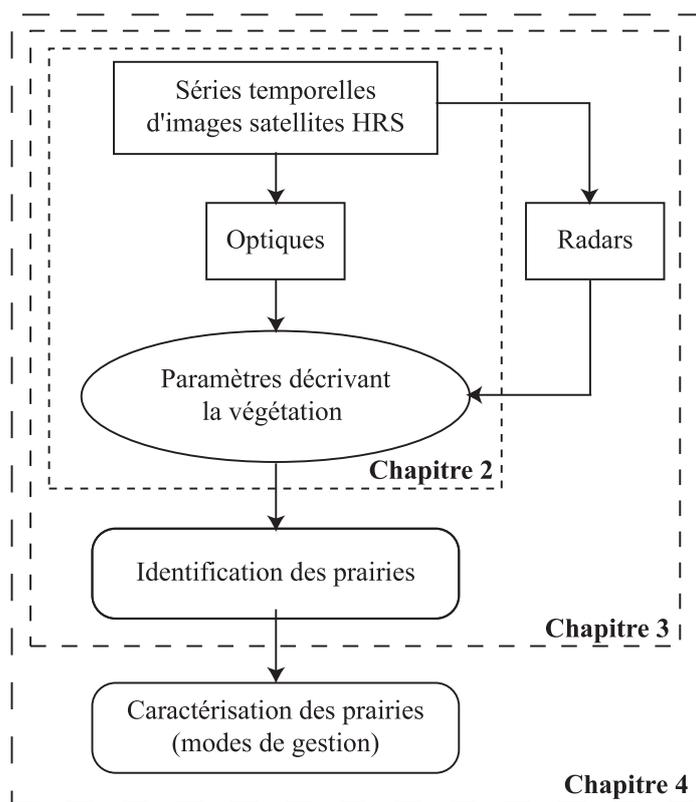


Figure 1 – Organisation générale de la thèse



# 1

## Identification, caractérisation et suivi des prairies par télédétection

### Sommaire

---

1.1	Éléments de contexte . . . . .	3
1.2	La télédétection : potentiel pour le suivi des prairies en milieu agricole	11
1.3	Le site d'étude . . . . .	35
1.4	Les données et leur traitement . . . . .	47
	Synthèse et conclusion du premier chapitre . . . . .	63

---



## 1.1. Éléments de contexte

---

### 1.1.1. Problématiques et enjeux de l'étude des prairies en milieu agricole

Depuis plusieurs décennies une diminution des surfaces en prairies est observée sur le territoire français. Elles occupent actuellement près de 30% du territoire (Eurostat, 2010), soit environ 45% de la Surface Agricole Utile (SAU) [Vigneau-Loustau & Huyghe 2008] contre 54% en 1970. C'est avec la politique de modernisation et d'intensification de l'agriculture, mise en œuvre dans les années 1970 pour répondre aux besoins alimentaires accrus de la population, que les surfaces en herbe ont diminué au profit des cultures céréalières et fourragères. Cette diminution s'est accélérée avec l'extension urbaine et l'augmentation des surfaces forestières (IFEN, 2004). Parallèlement, l'intensification de l'agriculture a entraîné une évolution des pratiques agricoles touchant les surfaces en herbe [Huyghe 2009]. Cette intensification s'est traduite, d'une part, par une baisse des prairies permanentes au profit des prairies temporaires rentrant dans les successions culturales des exploitations et d'autre part, par l'utilisation accrue de fertilisants chimiques qui a augmenté et accéléré la croissance de l'herbe, permettant d'intensifier et de diversifier les modes de gestion des prairies au cours de l'année.

En effet, les prairies jouent un rôle important tant sur le plan économique, pour la gestion des stocks de fourrages [Vigneau-Loustau & Huyghe 2008], que sur le plan environnemental (Figure 1.1) : les prairies contribuent à réguler les flux d'azote et de polluants (fertilisants et pesticides), préservant ainsi la qualité de l'eau et des sols [Vertès *et al.* 2010, Jannot 2007]. Ainsi, un couvert prairial continu dans le temps réduit le ruissellement de surface des polluants vers les cours d'eau [Gardi *et al.* 2002]. De plus, les prairies, en stockant davantage de carbone et d'azote sous forme organique dans les sols que les cultures, contribuent sensiblement à l'amélioration de la qualité de l'air [Soussana & Lüscher 2007, Jannot 2007]. Ainsi, les prairies participent à la lutte contre les émissions de gaz à effet de serre. Enfin, les systèmes prairiaux présentent une biodiversité floristique et faunistique importante notamment en zone de faible intensification [Metera *et al.* 2010]. En effet, les prairies sont généralement composées de nombreuses espèces fourragères, en association graminées/légumineuses présentant une diversité végétale plus importante que les grandes cultures mono-spécifiques. Les prairies constituent également des écosystèmes très favorables au développement des insectes, des lombrics et des micro-organismes [Cole *et al.* 2006]. Par ailleurs, à travers la diversité des habitats pour la reproduction, le refuge et l'alimentation, les prairies participent également au développement et à la préservation des oiseaux, des abeilles et des mammifères évoluant dans ce milieu [Granval 2000, Muller 2002] (Figure 1.1).

En milieu agricole, le rôle fonctionnel des prairies varie, d'une part, en fonction de leur nature et d'autre part, en fonction de leurs modes de gestion (fertilisation, fauche et/ou pâturage) ainsi que l'intensité de ces derniers [Vertès *et al.* 2007, Blüthgen *et al.* 2012]. Dès lors, si la composition et la durée des prairies influent sur leurs fonctions [Blüthgen *et al.* 2012],

	Services	Avantages
Économique	<ul style="list-style-type: none"> <li>• Élevage (fourrage pour les animaux)</li> </ul>	<ul style="list-style-type: none"> <li>• Biens alimentaires (viande, lait)</li> <li>• Fibres (laine, cuir)</li> <li>• Tourisme</li> </ul>
Environnemental	<ul style="list-style-type: none"> <li>• Qualité de l'eau (stockage de polluants)</li> <li>• Qualité des sols (limitation du risque d'érosion et de ruissellement, renouvellement)</li> <li>• Qualité de l'air (puits de carbone)</li> <li>• Diversité des espèces floristiques</li> <li>• Habitat faunique</li> </ul>	<ul style="list-style-type: none"> <li>• Eau potable</li> <li>• Conservation des sols, meilleure production, fertilité</li> <li>• Purification de l'air</li> <li>• Pollinisation accrue</li> <li>• Biodiversité végétale</li> <li>• Biodiversité animale</li> <li>• Ressource génétique (recherche scientifique : écologie, agronomie...)</li> </ul>

Figure 1.1 – Services et avantages rendus par les prairies

des pratiques telles que le sur-pâturage ou le retournement fréquent des parcelles génèrent des flux de nitrates élevés, un stockage de carbone limité et ainsi des risques importants de dégradation de la qualité de l'eau, des sols et de l'air [Vertès *et al.* 2007, Soussana & Lüscher 2007].

Au regard de leurs diverses fonctions, la régression des prairies pose plusieurs types de problèmes [Carrère 2012] parmi lesquels un manque de fourrage en cas de sécheresses estivales et une baisse du stockage du carbone et d'azote dans les sols. Face à la diminution régulière des prairies observée depuis plusieurs décennies et aux enjeux économiques et environnementaux qui en découlent, l'Union Européenne a mis en œuvre depuis 1992 des politiques encourageant le maintien des prairies [Plantureux *et al.* 2012]. En effet, elle impose à chaque État membre le maintien d'un pourcentage de prairies âgées de 5 ans et plus dans les surfaces agricoles (PAC 2010). La Politique Agricole Commune (PAC) actuellement en vigueur reconnaît le rôle fonctionnel des prairies notamment en les considérant comme « zones d'intérêt écologique », et devrait permettre d'enrayer la baisse des couverts prairiaux.

## 1.1.2. Les prairies en milieu agricole : caractéristiques et modes de gestion

### 1.1.2.1. Les types de prairie en secteur agricole

Le terme « prairie » recouvre des réalités très différentes et une grande diversité selon les milieux considérés et les activités humaines qui s'y exercent. Il existe plusieurs typologies permettant de décrire les prairies en milieu agricole, dont la plus simple, établie en 1998 par le Service Central des Études et Enquêtes Statistiques du ministère de l'Agriculture (SCEES), est basée sur leur composition botanique, leur durée et leur mode de gestion. Cette typologie distingue trois grandes catégories de prairies : 1- Les surfaces toujours en herbe ou prairies permanentes, 2- Les prairies temporaires et 3- Les prairies artificielles.

**Les surfaces toujours en herbe (STH) ou prairies permanentes** correspondent aux prairies de plus de 5 ans qui regroupent des prairies permanentes productives fauchées, ensilées et/ou pâturées et des prairies permanentes plus ou moins productives essentiellement utilisées par pâturage (Figure 1.2-a). Cette catégorie comprend des prairies bien différentes : des prairies permanentes « naturelles » implantées sur des sols non labourables (hydromorphes, superficiels, pentus, etc.), des prairies de longue durée, parfois anciennement semées ou améliorées par sur-semis, et des prairies semées (graminées pures, graminées et légumineuses, mélange de 3 à 7-8 espèces) pour une durée qui peut varier entre 5 et 10 ans, voir plus. Les graminées, appelées Poacées, sont des monocotylédones tel que le ray-grass, très largement semé en France. Les légumineuses, appelées Fabacées, sont des dicotylédones tels que le trèfle ou la luzerne. Celles-ci contribuent à la fixation de l'azote et en limite ainsi la diffusion dans les sols. Dans les régions dominées par les rotations fourragères, la durée des prairies diffère selon les objectifs poursuivis par l'agriculteur qui varient selon le type d'assolement, de production, les niveaux de production de l'herbe, les modes d'utilisation, etc. Le mode d'utilisation dominant des prairies permanentes est le pâturage, complété pour les systèmes fourragers herbagers par la constitution de stocks par fauche (ensilage, enrubanage, foin). En France, les prairies permanentes occupent une superficie d'environ 10 millions d'hectares.

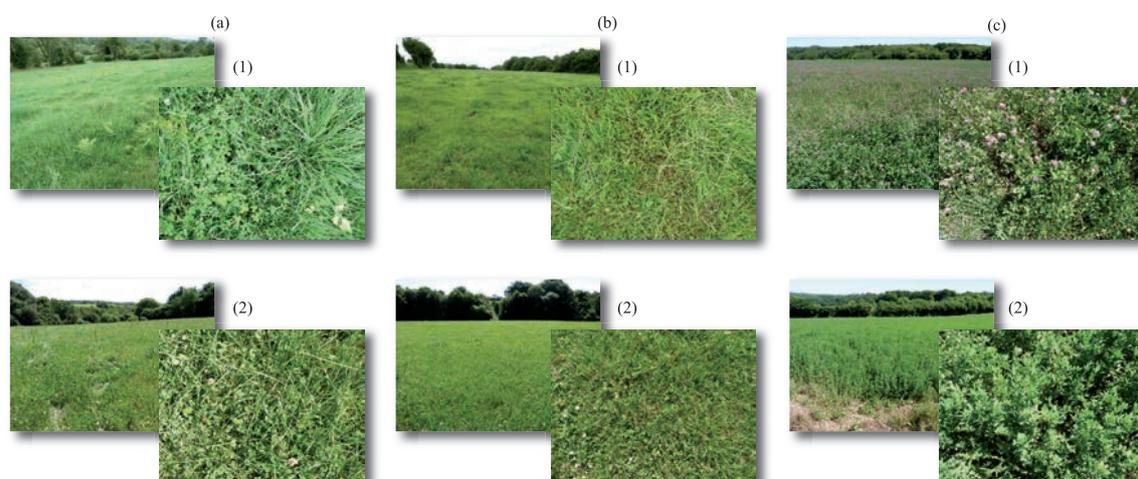


Figure 1.2 – Illustrations de prairies permanentes (a) : prairies pâturées composées de ray-grass et trèfles, avec présence de fougères (1) et rumex (2) ; illustrations de prairies temporaires (b) : prairie pâturée, composée principalement de ray-grass (1), prairie à usage mixte, composée de ray-grass et trèfles (2) ; illustrations de prairies artificielles (c) : prairie enssemencée en trèfle violet destinée à la fauche (1) et prairie enssemencée en luzerne destinée à la fauche (2)

**Les prairies temporaires**, illustrées par la figure 1.2-b, correspondent aux prairies âgées de 1 à 5 ans. Semées essentiellement en graminées fourragères et parfois associées à des légumineuses, ces prairies sont retournées au moins tous les 5 ans et généralement utilisées de façon assez intensive. Elles comprennent des prairies avec des graminées à forte production

mais peu pérennes, exploitées surtout en fauche, et des prairies avec ou sans légumineuses, exploitées majoritairement par pâturage.

**Les prairies artificielles** sont, elles, exclusivement ensemencées en légumineuses fourragères (Figure 1.2-c). Elles sont essentiellement composées de luzernières, généralement fauchées et ont une durée de vie moyenne de 4-5 ans.

### 1.1.2.2. Croissance des prairies et modes de gestion

Outre le choix des espèces et variétés, conditionné par le contexte pédoclimatique et les objectifs de l'agriculteur, les facteurs qui influencent la diversité floristique et la productivité des prairies relèvent de la gestion agricole des prairies (fertilisation, chargement animal, cycles fauche/pâturage, ...) mais aussi du régime hydrique et des températures, et de la nature de son environnement.

#### 1.1.2.2.1. La croissance de l'herbe

La saison végétative de la prairie débute lorsque les températures moyennes sont positives (graminées) ou supérieures à  $5^{\circ}C$  (trèfle blanc), donc au début du printemps pour les plaines de l'ouest de la France. Elle se termine lorsque ces conditions ne sont plus satisfaites. Durant cette période, les graminées prairiales passent par divers stades phénologiques (Figure 1.3) directement en relation avec le cumul des températures [Theau & Zerourou 2008, Jeangros & Amaudruz 2005] :

- Le départ en végétation : la hauteur de la végétation est comprise entre 5 et 10 cm, la température cumulée atteint  $300^{\circ}C$  ;
- Le stade de montaison (épi de 5 à 10 cm) : la hauteur de la végétation se situe entre 10 et 20 cm, la température cumulée est comprise entre  $500^{\circ}C$  et  $600^{\circ}C$  ;
- Le stade début d'épiaison (apparition des premiers épis hors de la graine) : la végétation atteint 20 cm, la température cumulée avoisine les  $750^{\circ}C$  ;
- Le stade d'épiaison (épis sortis de la graine) : la végétation atteint les 30 cm, la température cumulée est de  $1000^{\circ}C$  ;
- Le stade de floraison (étamines visibles) : la température cumulée est de  $1200^{\circ}C$ .

#### 1.1.2.2.2. Les modes de gestion associés aux prairies

Au cours de la période de croissance de la végétation, la prairie peut être exploitée selon différents modes : par pâturage, par fauche à différents stades, précoce pour l'ensilage ou l'enrubannage, plus tardif pour produire du foin (stock de fourrage) (Figure 1.3). Ainsi, dans l'ouest de la France, la période de mars à mai, qui correspond au stade de montaison, est la plus adaptée au pâturage. Ensuite, plusieurs cycles de pâturage peuvent se succéder pendant le reste de l'année, en respectant un temps de repousse minimum de 21 jours, soit tous les  $500^{\circ}C$ . Fin mai-début juin, lors du début de l'épiaison, les prairies sont gérées par ensilage ou enrubannage. Puis à partir de juin, au cours de l'épiaison, les prairies sont fauchées. De nombreuses parcelles sont exploitées en associant fauche et pâturage, la fauche correspondant

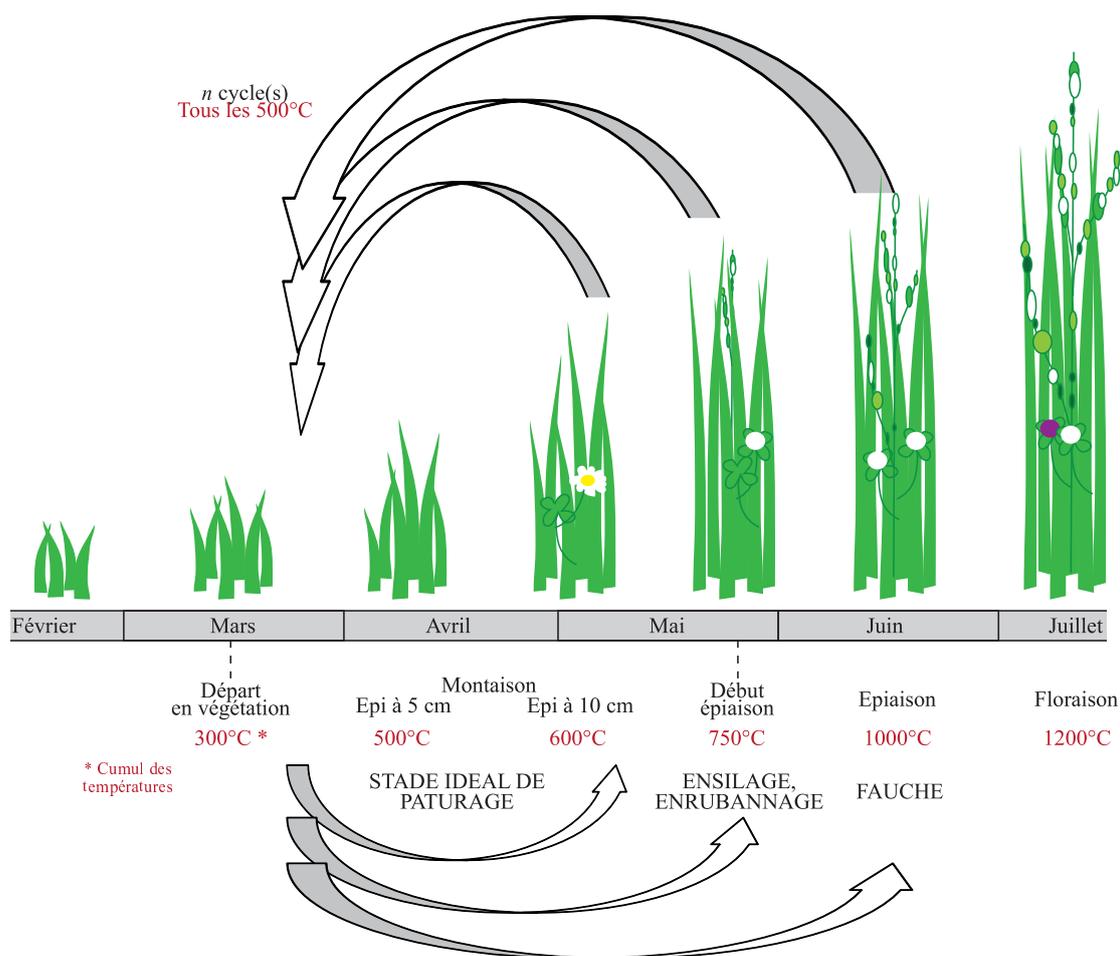


Figure 1.3 – Évolution phénologique de la prairie au cours d’une saison végétative

à une variable d’ajustement lorsque la disponibilité en herbe de la sole prairiale excède les besoins en pâturage des troupeaux.

Dans le cadre de l’expertise effectuée sur des bassins versant en contentieux en Bretagne, une étude a été menée pour inventorier les types de prairies à partir de bases de données (contrôle laitiers et suivi Teruti mené par le Ministère de l’agriculture). Cette étude montre que l’activité agricole sur les prairies débute au mois de mars et se termine entre septembre et décembre selon les zones climatiques. Au cours de cette période, fauches et/ou pâturages se succèdent, les pratiques différant selon le type de prairie considéré (Tableau 1.1).

Des prairies fauchées, pâturées et mixtes peuvent coexister dans une même exploitation agricole selon la structure des exploitations, les besoins des troupeaux et le choix des systèmes fourragers [Gueret 2006, Girard *et al.* 2001]. Le déprimage en sortie d’hiver, qui consiste en un passage rapide des animaux pour « nettoyer » le couvert des aléas hivernaux, retarder l’épiaison (consommation d’une partie des bourgeons) et le « pâturage du regain » en fin de saison est une pratique courante [Benoit *et al.* 1988]. Les pratiques réalisées sur les parcelles de prairies varient aussi selon leur localisation géographique par rapport au siège d’exploitation

Tableau 1.1 – Itinéraires techniques types des principales catégories de prairies situées en Bretagne Ouest et Centre (d’après Vertès F., communication)

Espèces	Fertilisation (kgN/ha/an)	Mode d’utilisation	Pâturage(s)	Fauche(s)
RGI	150	Fauche	Automne	Fin avril, fin juin
RGA	100 à 150	Pâturage	Mi-mars, fin avril, début juin, mi-juillet, début septembre, fin oct*	
	120 à 180	Pâturage + Fauche	Mi-mars, mi-juillet, début septembre, fin oct*	Début juin
	120 à 180	Fauche + Pâturage	Fin aout, fin oct*	Mi-juin
RGA-TB	50	Pâturage	Fin-mars, mi-mai, fin juin, début aout, mi-septembre, fin oct*	
	50 à 120	Pâturage + Fauche	Mi-juin, début septembre, fin oct*	Mi-avril
	50 à 120	Fauche + Pâturage	Mi-juillet, fin aout, fin oct*	Fin mai
Prairie Permanente	50 à 80	Pâturage	Début avril, début juin, début aout, mi-septembre	
	60 à 100	Fauche + Pâturage	Fin aout, fin oct*	Juin

\* Un dernier pâturage est souvent observé en octobre-novembre quand les sols sont portants

et le système d’élevage mis en œuvre (laitiers *versus* bovins). Ainsi, les parcelles pâturées sont proches du siège d’exploitation dans un système d’élevage laitier en raison des allers/retours biquotidiens de la salle de traite aux champs alors que dans un système d’élevage bovin les pâturages peuvent être plus éloignés. *A contrario*, la localisation des parcelles fauchées n’est pas conditionnée par leur distance au siège d’exploitation [Brunschwig *et al.* 2006].

#### 1.1.2.2.1. Le pâturage

Les prairies pâturées présentent généralement une strate herbacée basse, très dense au niveau du sol, irrégulière et plutôt hétérogène, souvent formée de touffes (refus du bétail) et de zones plus rases, broutées et piétinées (Figure 1.4-a). Les taches de refus résultent souvent de la présence de bouses ou de pissats (herbe très riche en azote). Des plantes comme le trèfle peuvent se développer dans les espaces ras [Gueret 2006]. Dans ces prairies, la végétation n’atteint pas le stade de développement complet (épiaison), qui s’accompagne d’une moindre appétence et digestibilité de l’herbe pour l’animal. Ce mode de gestion peut être optimisé en mettant en place le pâturage tournant, qui laisse l’herbe en repos entre deux pâturages [Grenier 2003]. Cette pratique nécessite un peu plus de travail (déplacement des clôtures et des animaux) que le pâturage continu mais permet une meilleure production et valorisation de l’herbe. Le pâturage continu est plus pratiqué sur des parcelles éloignées des sièges d’exploitations et réservées aux génisses, aux vaches tarées ou aux vaches allaitantes. Quand le pâturage est pratiqué de façon trop intensive dans une parcelle, le couvert végétal peut être

abîmé (dégâts de piétinement, végétation trop rase manquant de réserves pour repousser), on parle alors de sur-pâturage.

#### 1.1.2.2.2. *La fauche*

Dominées par des graminées telles la fétuque élevée, le dactyle, les ray-grass d'Italie et hybrides, les prairies exploitées en fauche peuvent atteindre des hauteurs importantes (plus d'un mètre) [Vigneau-Loustau & Huyghe 2008, Gueret 2006] (Figure 1.4-b). Selon les objectifs de récolte, elles se développent jusqu'au stade souhaité pour être ensuite fauchées et retrouver une structure rase, une ou plusieurs fois dans la saison (Figure 1.3).



Figure 1.4 – Illustrations de prairies pâturées (a) et fauchées (b)

#### 1.1.2.2.3. *L'exploitation mixte*

Ce mode de gestion correspond à l'utilisation combinée de la fauche et de la pâture sur une même parcelle durant la saison végétative. De manière générale, les prairies sont d'abord fauchées au printemps, lorsque la vitesse de croissance de la végétation est plus élevée. Les animaux sont ensuite mis à pâturer l'été, la production de biomasse étant modérée à cette période de l'année.

La distinction entre prairies de fauche et prairies de pâture est assez nette au niveau de

la physionomie quand un seul de ces deux modes de gestion est utilisé. Les prairies fauchées sont reconnaissables par leur hauteur et leur homogénéité de structure, tandis que les prairies pâturées s'identifient par leur hétérogénéité.

#### **1.1.2.2.4. Autres modes de gestion des prairies**

D'autres pratiques peuvent être mises en œuvre sur les prairies. Ainsi, la fertilisation minérale et/ou organique [Vertès *et al.* 2007] joue un rôle de premier plan dans la conduite de la prairie en influant sur la vitesse de croissance, la quantité de biomasse produite, la qualité de l'herbe (teneur en N, digestibilité) et sa composition floristique. Ce mode de gestion se manifeste généralement par un changement de couleur des prairies (vert plus sombre). Les apports d'engrais ou d'effluents organiques ont lieu entre février et juin sur les graminées. Lorsque le trèfle est bien présent dans les associations végétales, et qu'il peut donc assurer la nutrition azotée du couvert, les éleveurs fertilisent peu ou pas leurs prairies.

En plus des pratiques de fertilisation, de pâturage et de fauche, les prairies peuvent être détruites en particulier pour faire place à une culture fourragère (généralement du maïs) avec un très bon rendement sans fertilisation [Vertès *et al.* 2007, Pousset 2002]. Le retournement de la prairie peut être effectué de façon mécanique (par labour, plus ou moins profond) ou chimiquement (en répandant des produits comme le glyphosate par exemple), en étant suivi d'un travail du sol superficiel ou d'un labour. Ces deux modes de destruction produisent des états de surfaces très différents : un sol nu avec des sillons plus ou moins marqués dans un cas, un sol recouvert par des résidus de végétation sénescente dans l'autre (couleur jaune).

Le sur-semis est généralement effectué pour rénover et augmenter la productivité de vieilles prairies [Lemasson *et al.* 2008]. Il se traduit par une augmentation de la densité du couvert herbeux et de l'homogénéisation de l'état de surface des parcelles concernées.

Le retournement, le sur-semis comme la fertilisation sont motivés par un souci de rendement. Dans un contexte d'intensification agricole, l'augmentation de la fertilisation et de la fréquence de retournement des prairies s'accompagne d'une augmentation du nombre de coupes ou de pâturages (chargement animal excessif avec un risque de sur-pâturage) [Janot 2007].

Ces différents modes d'exploitation des prairies ont des impacts sur l'environnement, notamment sur la qualité des eaux, qui ont déjà été étudiés [Vertès *et al.* 2010, Vertès *et al.* 2007]. Nous ne détaillerons pas ces effets, mais l'un des enjeux de l'identification et de la caractérisation des prairies par télédétection est de pouvoir repérer des situations à risques : forte fertilisation, période et mode de destruction, période et nombre de fauches, période et nombre de mises en pâturage, évaluation du chargement animal, etc.

## 1.2. La télédétection : potentiel pour le suivi des prairies en milieu agricole

---

### 1.2.1. Caractéristiques des données de télédétection utilisables pour l'étude des prairies

Les données de télédétection utilisables pour étudier les prairies peuvent être acquises dans deux domaines différents : le domaine optique et le domaine des hyperfréquences.

#### 1.2.1.1. Télédétection passive et télédétection active

La télédétection permet l'étude des caractéristiques physiques et biologiques des surfaces terrestres sans contact direct avec celles-ci à travers l'acquisition à distance du rayonnement électromagnétique émis et/ou réfléchi par les surfaces terrestres. Deux types d'acquisition se distinguent : l'acquisition passive lorsque le rayonnement électromagnétique provient d'une source naturelle comme le soleil (Figure 1.5-a) et l'acquisition active lorsque le rayonnement provient d'une source artificielle (capteur) (Figure 1.5-b). En télédétection passive, le rayonnement est réfléchi par la surface terrestre dans les longueurs d'onde du visible et du proche infrarouge, qui appartiennent au domaine optique. En télédétection active, le rayonnement est émis en direction de la surface terrestre par le capteur et rétrodiffusé (renvoyé) à ce dernier dans les longueurs d'onde du domaine des hyperfréquences (capteurs RADAR - Radio Detection And Ranging) (Figure 1.5-c). Notons que la télédétection active n'est que très faiblement sensible aux conditions atmosphériques et d'illuminations. Ainsi, de nuit comme de jour, et par temps couvert des images peuvent être acquises, alors que la télédétection passive dépend de l'ensoleillement (pas d'acquisition exploitable la nuit) et est très sensible aux conditions atmosphériques et en particulier à la présence de nuages. Selon la nature de l'état des surfaces terrestres, le rayonnement réfléchi varie. De plus, l'état de l'atmosphère, les conditions d'illuminations, l'environnement des surfaces et le capteur utilisé influencent la capacité du rayonnement à être émis et réfléchi. Ainsi, une partie du rayonnement peut être diffusée par l'atmosphère, une autre peut être transmise et/ou absorbée par le sol et une dernière est réfléchie (Figure 1.5). La fraction du rayonnement incident réfléchi par les surfaces terrestres en fonction des longueurs d'ondes est enregistrée par différents capteurs, embarqués principalement à bord de satellites ou d'avions.

Les capteurs optiques sont caractérisés selon leur résolution spatiale, spectrale et temporelle qui varient selon les domaines d'application [Xie *et al.* 2008, Girard & Girard 1999]. Dans le domaine des hyperfréquences, les radars sont caractérisés selon leur résolution spatiale et temporelle ainsi que par leur fréquence d'émission, leur polarisation d'émission et de réception et leur angle d'incidence. Les différentes caractéristiques des principaux capteurs exploitables pour l'étude des prairies sont présentées dans le tableau 1.2.

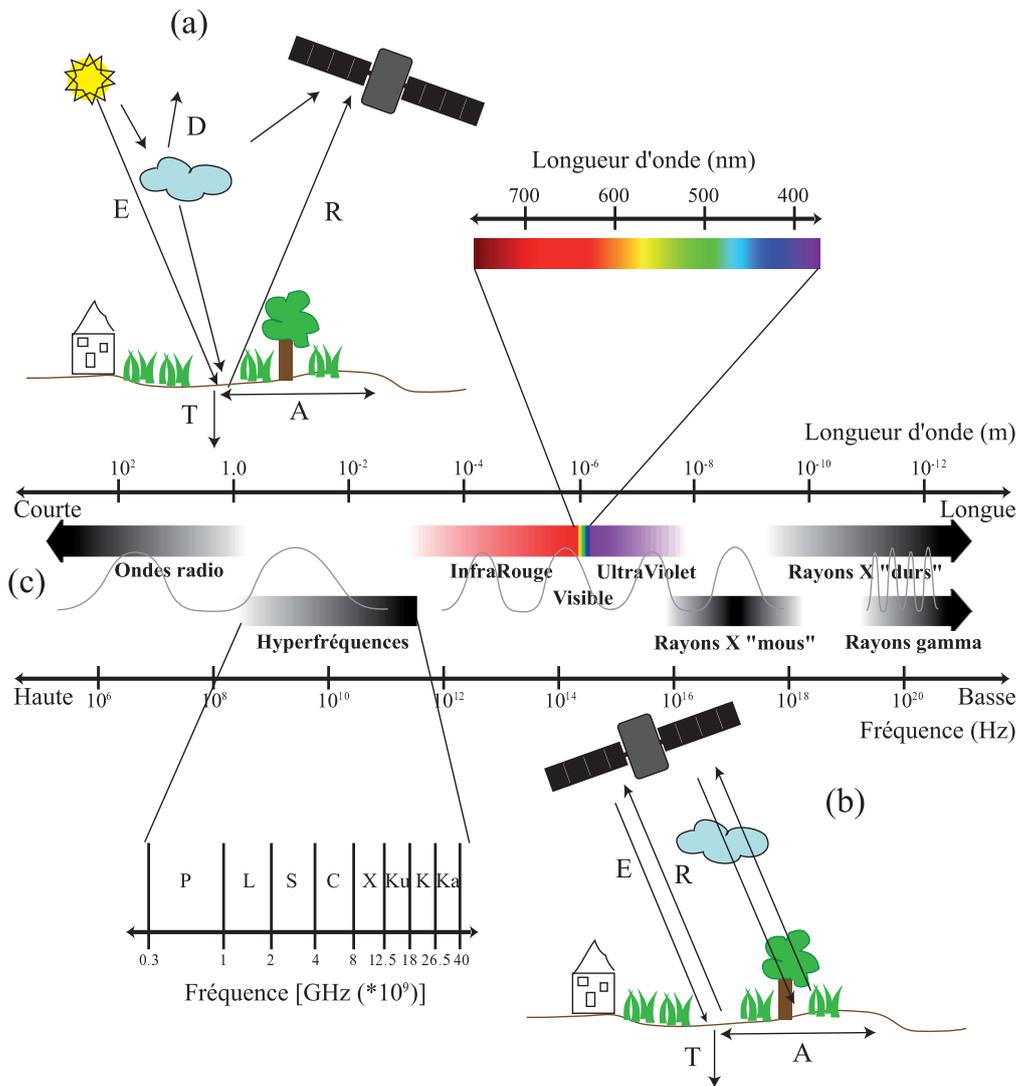


Figure 1.5 – Interaction du rayonnement électromagnétique avec la surface terrestre en télédétection passive (a) et en télédétection active (b). Principaux domaines du spectre électromagnétique (c) (E : Rayonnement incident/émis, T : transmis, A : absorbé, D : diffusé, R : réfléchi)

Tableau 1.2 – Caractéristiques des principaux capteurs et satellites utilisables pour l'étude des prairies en milieu agricole

Satellite	Domaine	Résolution spectrale / Bande	Bande / Polarisation	Résolution spatiale (m)	Résolution temporelle (j)	Fauchée (km)
<b>Satellite à Très Haute Résolution Spatiale (THRS)</b>						
<b>CASI**</b>	Optique	Hyperspectral	288	2,5		
<b>COSMO-SkyMed**</b>	Radar	Bande X	double	de 1 à 30	10	de 10 à 200
<b>GEOEYE-1**</b>	Optique	Panchromatique Multispectral	1 4	0,41 1,65	<3	15,2
<b>IKONOS-2**</b>	Optique	Panchromatique Multispectral	1 4	1 4	2-3	11
<b>PLEIADES***</b>	Optique	Panchromatique Multispectral	1 4	0,5 2	2	20
<b>QUICKBIRD-2**</b>	Optique	Panchromatique Multispectral	1 4	0,6 2,5	3-7	16,5
<b>RADARSAT-2**</b>	Radar	Bande C	polarimétrique	de 3 à 100	24	de 45 à 500
<b>SPOT 6,7 - NAOMI***</b>	Optique	Panchromatique Multispectral	1 4	1,5 6	26	60
<b>TERRASAR-X**</b>	Radar	Bande X	double	1	11	10 * 5
<b>WORLDVIEW-2**</b>	Optique	Panchromatique Multispectral	1 8	0,5 1,8	1-4	16,4

Satellite	Domaine	Résolution spectrale / Bande	Bande / Polarisation	Résolution spatiale (m)	Résolution temporelle (j)	Fauchée (km)
<b>Satellite à Haute Résolution Spatiale (HRS)</b>						
<b>ALOS**</b>	Optique	Panchromatique	1	2,5	2	40
		Multispectral	4	10		
<b>ALOS - PALSAR**</b>	Radar	Bande L	polarimétrique	10	2	40
		Multispectral	3	15	16	60
<b>ASTER**</b>	Optique	Multispectral	6	30		
		Hyperspectral	224	20		12
<b>ENVISAT/ASAR**</b>	Radar	Bande C	double	de 30 à 1000	23	de 10 à 400
	Radar	Bande C	VV	de 30	35	de 100
<b>FORMOSAT-2**</b>	Optique	Panchromatique	1	2	1-2	24
		Multispectral	4	8		
<b>HJ-1C***</b>	Radar	Bande S	VV	de 4 à 25		de 35 à 105
<b>HYPERION**</b>	Optique	Hyperspectral	242	30	16	
<b>LANDSAT 4,5 - TM**</b>	Optique	Multispectral	7	30	16	185
<b>LANDSAT 7 - ETM+**</b>	Optique	Panchromatique	1	15	16	185
		Multispectral	7	30		
<b>LANDSAT 8 - LDCM***</b>	Optique	Panchromatique	1	15	16	185
		Multispectral	8	30		
<b>RADARSAT-1**</b>	Radar	Bande C	simple	de 8 à 100	24	de 45 à 500
<b>SENTINEL-2***</b>	Optique	Multispectral	13	10	5	290

Satellite	Domaine	Résolution spectrale / Bande	Bande / Polarisation	Résolution spatiale (m)	Résolution temporelle (j)	Fauchée (km)
SPOT 1,2,3 - HRV*	Optique	Panchromatique	1	10	26	60
		Multispectral	3	20		
SPOT 4 - HRVIR**	Optique	Panchromatique	1	10	26	60
		Multispectral	4	20		
SPOT 5 - HRS**	Optique	Panchromatique	1	5	26	60
		Multispectral	4	10		
VENUS***	Optique	Multispectral	12	10	5	28

#### Satellite à Moyenne Résolution Spatiale (MRS)

HJ-1A**	Optique	Hyperspectral	115	100	de 4 à 31	50
MODIS**	Optique	Multispectral	36	250	2	2330

#### Satellite à Basse Résolution Spatiale (BRS)

SPOT - VEGETATION**	Optique	Multispectral	4	1000	1	22500
NOAA**	Optique	Multispectral	6	de 500 à 1000	1	2940

\*capteur plus opérationnel en 2010, \*\*capteur opérationnel en 2010, \*\*\*capteur opérationnel après 2010

### 1.2.1.2. Les données acquises dans le domaine optique

#### 1.2.1.2.1. La résolution spatiale

La résolution spatiale d'un capteur correspond à la taille minimum des objets pouvant être identifiés au sol, ce qui correspond en télédétection à la taille des pixels d'une image satellite (picture element). La capacité à distinguer deux objets voisins différents dépend donc de la résolution spatiale du capteur. Celle-ci peut varier du kilomètre, pour des capteurs à basse résolution spatiale (tels que NOAA AVHRR, SPOT Vegetation, ...), utilisés le plus souvent pour des applications météorologiques ou pour cartographier la couverture terrestre à l'échelle globale, au mètre pour des capteurs à haute et très haute résolution spatiale (HRS et THRS) (tels que SPOT, RapidEye, Pléiades, ...), utilisés pour étudier des objets géographiques fins de type parcelle agricole par exemple [Duveiller & Defourny 2010] (Figure 1.6).

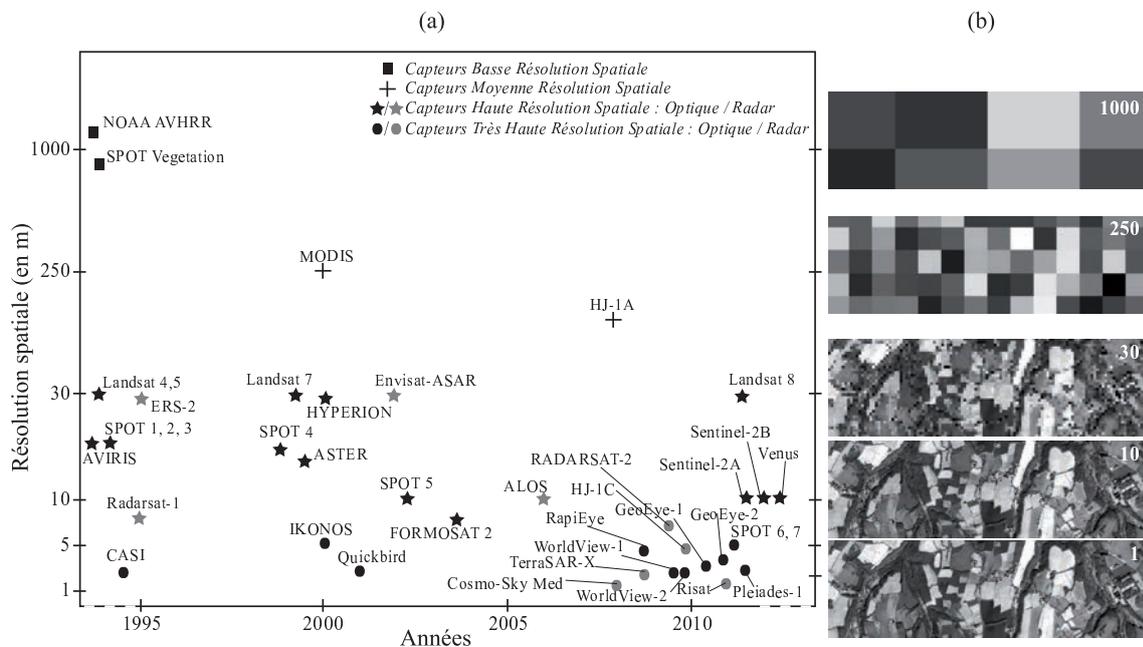


Figure 1.6 – Résolution spatiale des capteurs spatiaux d'observation de la Terre en fonctionnement ou programmés pour un lancement avant 2014 (a) et extrait d'une image GeoEye initialement à 1m de résolution, dégradée à des résolutions spatiales plus faibles (b)

Pour cartographier des objets telles que des prairies et les pratiques agricoles qui leur sont associées, en milieu agricole hétérogène et fragmenté, la haute résolution spatiale au minimum (résolution égale ou inférieure à 30 mètres) est indispensable [Lecerf 2008, Girard & Benoit 1990, Benoit *et al.* 1989].

#### 1.2.1.2.2. La résolution temporelle

La résolution temporelle ou répétitivité, qui correspond à la capacité de revisite d'un capteur sur un même site d'étude, est inversement proportionnelle à la résolution spatiale. Ainsi, un capteur à haute résolution spatiale a une plus faible capacité de revisite qu'un capteur à basse résolution spatiale, respectivement d'un ordre mensuel à un ordre journalier (par exemple SPOT *versus* MODIS). De plus, pour les images acquises dans le domaine optique, la résolution temporelle est altérée selon les conditions atmosphériques (couverture nuageuse) : une image peut être acquise tous les mois (résolution temporelle réelle) mais seulement une image tous les 6 mois peut être utilisée (résolution temporelle effective). Ainsi, il devient impossible de suivre l'évolution du couvert végétal lorsque le capteur ne possède pas de capacité de dépointage (exemple : Landsat). La seule solution consiste à utiliser toutes les images disponibles en archive et à compléter ces séries temporelles par des images qui ont fait l'objet de programmation. Dans ce contexte, la mise en orbite prochaine de capteurs à haute résolution spatiale et temporelle (missions spatiales Ven $\mu$ s et Sentinel-2) ouvre de nouvelles perspectives pour l'étude de l'occupation et de l'utilisation des sols à échelle fine.

#### 1.2.1.2.3. La résolution spectrale

La résolution spectrale est la capacité d'un capteur à distinguer deux longueurs d'ondes voisines. La résolution spectrale est définie par le nombre de bandes spectrales disponibles. Ainsi, un capteur multispectral tels que SPOT ou Quickbird, qui est caractérisé par un faible nombre de bandes spectrales (de l'ordre de 3 à 5 principalement) à large spectre (supérieur à  $100\mu m$ ) possède une faible résolution spectrale. À l'inverse, un capteur hyperspectral tels que AVIRIS ou HySpex, qui est caractérisé par un nombre important de bandes spectrales (plus de 100) à spectre étroit (de l'ordre du  $nm$ ) possède une haute résolution spectrale. Plus la résolution spectrale est importante, plus la signature spectrale définissant l'objet au sol est précise et permet de bien discriminer les objets terrestres.

#### 1.2.1.3. Les données acquises dans le domaine des hyperfréquences

Les radars (Radio Detection And Ranging - détection et estimation de la distance par ondes radio) utilisés en télédétection spatiale sont des radars à synthèse d'ouverture (RSO), appelés plus couramment SAR (Synthetic Aperture Radar). Outre les résolution spatiale et temporelle définies précédemment pour les capteurs fonctionnant dans le domaine optique, un SAR est caractérisé par la fréquence d'émission ou longueur d'onde, la polarisation d'émission et de réception et l'angle d'incidence.

##### 1.2.1.3.1. La fréquence d'émission ou longueur d'onde

Les bandes de longueur d'onde hyperfréquences de  $0.75cm$  à  $1m$  (nommée Ka à P respectivement) sont principalement utilisées par les systèmes RADAR spatiaux et aéroportés (Figure 1.5-c) dont la capacité à pénétrer les surfaces varie en fonction de la bande considérée. Ainsi, plus la longueur d'onde d'acquisition est élevée plus le rayonnement pénètre dans les surfaces [Ulaby *et al.* 1982]. Les SARs adaptés au suivi de la végétation se situent plutôt dans

les bandes X, C et L [Wang *et al.* 2013, Baghdadi *et al.* 2009, Inoue *et al.* 2002]. En pratique, seules ces bandes sont présentes sur les satellites d'observation de la Terre actuellement en fonctionnement. Les bandes X et C sont utilisées pour l'identification des cultures alors que la bande L est utilisée pour le suivi des couverts forestiers [Pregon & Yamagata 2013, McNairn & Brisco 2004].

#### 1.2.1.3.2. La polarisation d'émission et de réception

La polarisation d'un capteur SAR est exclusivement de type linéaire. Elle peut être soit horizontale (H) ou verticale (V). Les polarisations possibles sont HH, VV, HV ou VH, la première lettre désignant la polarisation d'émission, la seconde la polarisation de réception. Lorsque les polarisations d'émission et de réception sont identiques (HH et VV), le SAR est dit à co-polarisation (ou polarisation parallèle). Lorsque la polarisation d'émission est différente de celle de réception (HV et VH), le SAR est dit à polarisation croisée. Les capteurs en polarisation croisée (« Full polarization ») sont fréquemment utilisés pour l'identification des cultures car en plus des intensités de polarisation en HH, VV, HV et VH ( $\sigma^0$  dB), des paramètres et discriminateurs polarimétriques peuvent être extraits des images.

#### 1.2.1.3.3. L'angle d'incidence

L'angle d'incidence correspond à l'angle formé entre l'onde émise et la surface au sol visée. Il varie entre une quinzaine et une cinquantaine de degrés. Lorsque les images sont acquises avec un angle d'incidence relativement important (supérieur à  $37^\circ$ ) le signal rétrodiffusé est plus sensible au couvert végétal. *A contrario*, lorsque l'angle d'incidence est faible, le signal rétrodiffusé est plus sensible au sol.

### 1.2.2. Télédétection et prairies : état de l'art

La télédétection produit des données à partir desquelles il est possible d'extraire des informations décrivant l'état des surfaces terrestres. Les paramètres et variables dérivés des images de télédétection utilisés pour identifier et caractériser les prairies proviennent de deux types de capteurs : dans le domaine optique il s'agit de radiomètres et dans le domaine des hyperfréquences de radars. Selon le type de capteur utilisé, la nature des données acquises et des paramètres qui en sont dérivés est très différente.

#### 1.2.2.1. L'usage des images satellites acquises dans le domaine optique

##### 1.2.2.1.1. La signature spectrale de la végétation

Généralement, les bandes du rouge (de  $0.6\mu\text{m}$  à  $0.7\mu\text{m}$ ) et du proche infrarouge (de  $0.7\mu\text{m}$  à  $1.5\mu\text{m}$ ) sont les plus couramment utilisées pour étudier l'activité photo-synthétique et chlorophyllienne des plantes, leur densité, le rendement des cultures et la répartition spatiale des espèces [Xie *et al.* 2008]. La réponse spectrale de la végétation est caractérisée par une faible réflectance dans la bande rouge (pic d'absorption de la chlorophylle), et une réflectance

beaucoup plus élevée dans le proche infrarouge (Figure 1.7). Le domaine du moyen infrarouge (de 1.5 à 3 $\mu m$ ) permet, quant à lui, d'estimer les teneurs en eau des surfaces. Ainsi, il est très utilisé pour cartographier les couverts végétaux en état de stress hydrique. Toutefois, le stade phénologique, la densité et l'état hydrique de la végétation et le mode de gestion, ainsi que le sol sous-jacent influencent la réponse spectrale des couverts végétaux [Girard & Girard 1999] (voir section 1.2.3). Ainsi, la figure 1.8-a montre que plus la couverture végétale est dense, plus les valeurs de réflectance sont élevées dans le proche infrarouge et faibles dans le rouge. L'évolution de la couverture végétale durant la saison végétative peut donc être étudiée en utilisant ces bandes spectrales (Figure 1.8-b).

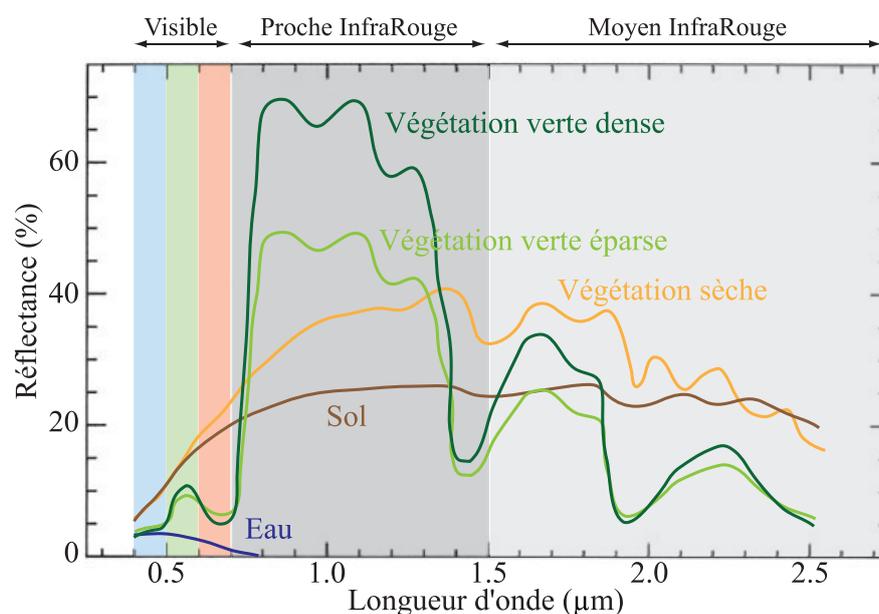


Figure 1.7 – Signatures spectrales de la végétation

Par ailleurs, si la réponse spectrale des couverts a été le plus souvent le critère d'identification privilégié pour étudier les prairies, la texture des images pourrait aussi être exploitée pour caractériser les prairies, par exemple identifier le pâturage qui entraîne des hétérogénéités de surface. Toutefois, ce critère n'est utilisable que sur des images à très haute résolution spatiale [Lefebvre 2011].

#### 1.2.2.1.2. Les données

Dans le domaine optique, la grande majorité des recherches centrées sur l'étude des prairies par télédétection visent soit à discriminer les prairies des autres couverts végétaux (blé d'hiver, maïs, ...), soit à estimer des paramètres décrivant la couverture végétale tels que la densité et l'état du couvert végétal, le taux de couverture par la végétation ou la biomasse. Les données utilisées varient selon le ou les objectif(s) à atteindre mais aussi selon les caractéristiques du site d'étude (étendue du site et taille des parcelles).

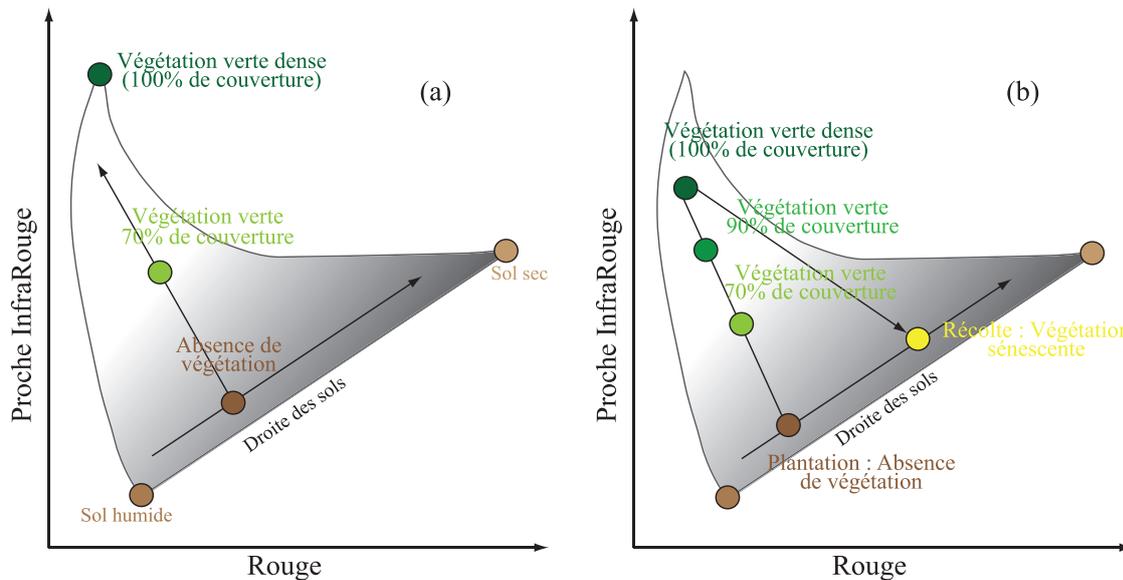


Figure 1.8 – Répartition dans l'espace rouge/proche infrarouge (a) de pixels avec et sans couverture végétale et (b) d'un pixel de végétation au cours de la saison végétative (d'après [Jensen 2000])

Plusieurs études menées avec des séries temporelles d'images provenant de capteurs à moyenne résolution, tels que MODIS ou SPOT-Vegetation ont montré l'intérêt et les limites de ce type de données pour l'étude des prairies [Lecerf 2008, Li *et al.* 2013, Geerken *et al.* 2005, Hill *et al.* 1999b]. D'une part, de telles images couvrent de larges superficies ce qui permet de réaliser des inventaires à l'échelle d'un pays, voir d'un continent [Beurs & Henebry 2010, Doraiswamy *et al.* 2007, Tucker *et al.* 1985]. D'autre part, la répétitivité des observations journalières à moyenne et basse résolution apparaît comme un atout majeur pour distinguer les prairies des cultures [Brown *et al.* 2013, Hill & Donald 2003]. Néanmoins, si elles sont adaptées aux paysages à large parcellaire, ces données ont une résolution spatiale (250m\*250m au mieux) qui n'est pas adaptée à l'étude des prairies dans des régions de petit parcellaire. Dans ce cas, seuls des îlots parcellaires à dominante prairiale peuvent être détectés [Lecerf 2008, Zhang *et al.* 2003]. Ainsi, avec ce niveau de précision, il n'est pas envisageable d'identifier les pratiques agricoles sur les prairies.

La plupart des études menées sur les prairies par télédétection utilisent des images à haute résolution spatiale (5-30m), de type Landsat ou SPOT. L'exploitation d'une à trois images acquises au cours d'une même année permet d'identifier les prairies sur des surfaces de quelques centaines de  $km^2$  [Zhang & Guo 2008, Cingolani *et al.* 2004, Girard & Benoit 1990]. Le traitement de séries temporelles composées de une à trois images par an sur quelques années permet quant à elles, de déterminer l'évolution inter-annuelle des prairies en précisant leur durée et leur place dans les successions culturales et leur taux de recouvrement [Vannier 2012, Guo 2004, Benoit *et al.* 1988]. Cependant, les informations dérivées de ces images

ne sont pas très précises en raison du trop faible nombre d'image utilisé pour discriminer correctement les prairies des autres couverts végétaux. En effet, d'importantes confusions sont observées entre les prairies et les cultures comme les blés d'hiver ou le maïs qui montrent des réponses spectrales similaires aux prairies en fonction des dates d'acquisition des images et du stade de croissance des différents couverts végétaux [Doraiswamy *et al.* 2007, Wessels *et al.* 2004]. La répétitivité limitée des capteurs enregistrant des images à haute résolution spatiale couplée à la fréquence de la couverture nuageuse constitue une limite forte non seulement pour identifier les prairies mais aussi *a fortiori* pour détecter les pratiques agricoles qui y sont effectuées [Rapinel *et al.* 2014, Jensen *et al.* 2006, Debinski *et al.* 1999, Benoit *et al.* 1989].

Plus rarement, d'autres types de données optiques sont utilisées pour étudier les prairies : des images hyperspectrales et des images multispectrales à très haute résolution spatiale. Ainsi, des études ont montré l'intérêt des données LiDAR (Light Detection And Ranging) pour étudier et caractériser la structure de la végétation [Rapinel 2012], ces données permettant, grâce à leur très forte résolution spectrale -souvent combinée à une très bonne résolution spatiale-, de discriminer des espèces végétales et de décrire finement l'état des couverts végétaux [Lausch *et al.* 2013, Hubert-Moy *et al.* 2003]. Les données acquises plus récemment par des capteurs à très haute résolution spatiale tel que Worldview ou GEOEYE devraient permettre d'identifier et de caractériser finement l'état du couvert végétale [Rapinel *et al.* 2014]. Cependant, qu'il s'agisse des données hyperspectrales et/ou à très haute résolution spatiale, ces données présentent deux inconvénients : elles couvrent des surfaces réduites (quelques dizaines de  $km^2$ ) et leur coût est très élevé, ce qui limite leur fréquence d'acquisition. Ainsi, il n'est pas envisageable d'exploiter ces données pour inventorier les prairies et les pratiques qui leurs sont associées sur des étendues dont la taille est compatible avec la gestion des territoires agricoles.

### 1.2.2.1.3. Les paramètres dérivés des images optiques pour le suivi des prairies

Les prairies peuvent être étudiées à travers l'utilisation de paramètres dérivés des images de télédétection, soit le plus souvent en calculant des indices de végétation à partir des mesures directes de réflectance (Figure 1.9, NDVI), soit en estimant des variables biophysiques par l'application d'un modèle de transfert radiatif (modèle physique) (Figure 1.9, LAI).

#### 1.2.2.1.3.1. Les indices de végétation

Les indices de végétation sont principalement basés sur le comportement spectral de la végétation dans les canaux du Rouge (R) et du Proche InfraRouge (PIR) [Viña *et al.* 2011, Dorigo *et al.* 2007, Bannari *et al.* 1995, Neigh *et al.* 2008, Benoit *et al.* 1988, Tucker 1979]. Parmi les nombreux indices existants, le NDVI (Normalized Difference Vegetation Index) est l'indice le plus couramment utilisé [Rouse *et al.* 1974]. Toutefois, il est sensible aux effets du sol sous-jacent et à l'atmosphère [Montandon & Small 2008, Henebry 1993, Baret & Guyot 1991, Huete *et al.* 1985]. Les indices dérivés du calcul de la droite des sols, tel que le TSAVI (Transformed Soil Adjusted Vegetation Index) minimisent l'influence du sol [Baret & Guyot 1991, Baret *et al.* 1989], tandis que d'autres indices tel que le ARVI (Atmospherically Resistant Vegetation Index) sont moins sensibles aux effets de l'atmosphère [Kaufman & Re-

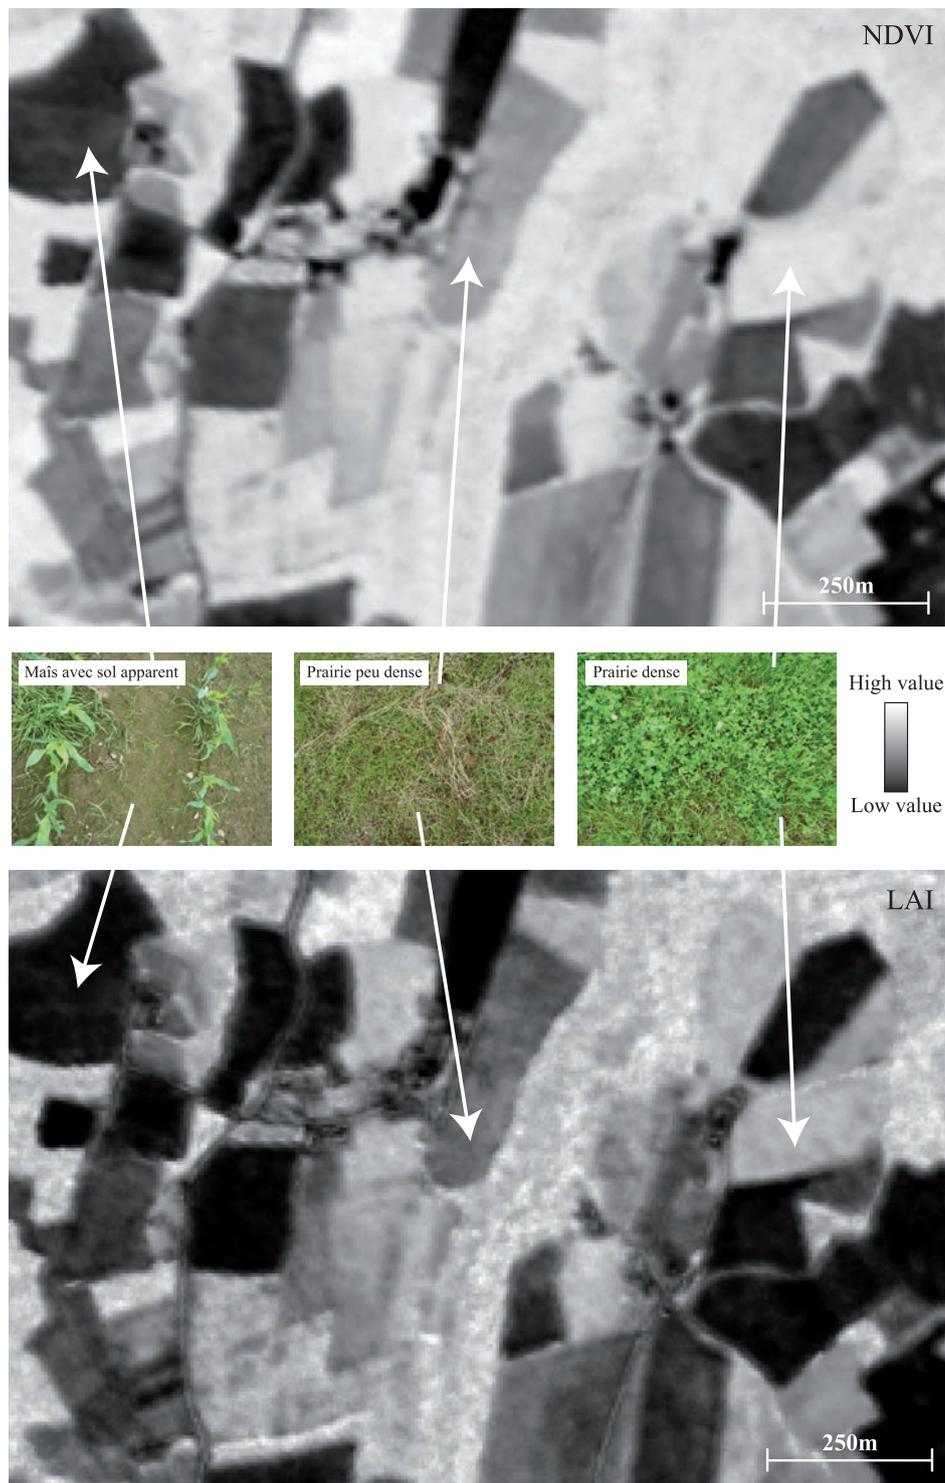


Figure 1.9 – Images du NDVI et du LAI dérivées sur un extrait de l'image SPOT 5 du 26/06/2010

mer 1994] et permettent une meilleure détermination des caractéristiques de la végétation. Cependant, de manière générale, les indices de végétation ne prennent pas en compte les caractéristiques des capteurs (une même surface végétale vue par deux capteurs différents n'aura pas les mêmes valeurs d'indices) [Jiang *et al.* 2006, Franke *et al.* 2006, Jacquemoud & Baret 1990, Baret *et al.* 1989]. De plus, plusieurs études ont montré une relation non linéaire entre les indices de végétation et l'état de la végétation [Edirisinghe *et al.* 2011, Viña *et al.* 2011, Huete *et al.* 1985, Carlson & Ripley 1997], les indices de végétation saturant sur une surface végétale dense [Huete *et al.* 1997]. En effet, des études ont montré que pour des taux de couverture végétale supérieurs à 60%, les indices de végétation utilisant le canal du PIR sont insensibles aux changements liés à la végétation [Gitelson *et al.* 2002, Glenn *et al.* 2008, Wu *et al.* 2007, Diaz & Blackburn 2003]. Néanmoins, malgré l'intérêt des indices tels que le TSAVI, le ARVI, . . . , et les limites du NDVI ce dernier est encore très majoritairement utilisé dans la communauté scientifique en télédétection car il est facile à calculer et à interpréter [Fontana *et al.* 2008, Wang *et al.* 2005, Henebry 1993].

#### 1.2.2.1.3.2. Les variables biophysiques

L'exploitation de variables biophysiques, tels que l'indice de surface foliaire -LAI (Leaf Area Index)-, la fraction de couverture végétale verte -fCOVER (fraction of Vegetation Cover)- ou la fraction de rayonnement électromagnétique absorbée par les surfaces terrestres pour la photosynthèse -fAPAR (fraction of Absorbed Photosynthetically Active Radiation )-, permet d'analyser l'état des couverts végétaux en fonction de la croissance de la végétation et des pratiques agricoles. Ces variables biophysiques sont principalement estimées de deux manières [Darvishzadeh *et al.* 2011] : par des méthodes empiriques ou semi-empiriques ou par l'application de modèles de transfert radiatif.

Dans le premier cas, l'estimation des variables biophysiques est basée sur des relations statistiques (le plus souvent une simple relation linéaire) établies généralement entre des données directement mesurées au sol (LAI, hauteur de végétation, biomasse) et les valeurs d'indices de végétation calculées à partir des images de télédétection [Potithec *et al.* 2013, Gao *et al.* 2012, Wu *et al.* 2010, Zheng & Moskal 2009, Wylie *et al.* 2002, Richardson *et al.* 1982]. Cependant, la sous-estimation du NDVI pour des surfaces végétales ayant un taux de couverture supérieur à 60% entraîne une relation non linéaire entre les indices de végétation et les variables biophysiques [Toby & Ripley 1997, Baret & Guyot 1991]. En conséquence, l'estimation précise des variables biophysiques nécessite d'utiliser une autre méthode que le calcul d'indices de végétation [Ji & Peters 2007, Jacquemoud *et al.* 2006].

Dans le second cas, l'estimation des variables biophysiques est basée sur l'utilisation de modèles de transfert radiatif. La théorie du transfert radiatif, qui décrit la propagation du rayonnement électromagnétique à travers la matière, est largement appliquée en télédétection spatiale, car elle permet de déduire les propriétés physiques d'objets à partir du rayonnement électromagnétique observé [Jacquemoud *et al.* 2009]. Différents modèles ont été développés afin de simuler le transfert du rayonnement pour différents milieux. On distingue généralement les modèles directs des modèles inverses du transfert radiatif : les premiers permettent

d'estimer la Fonction de Distribution de la Réflectance Bidirectionnelle (FDRB) de certains milieux en fonction des paramètres biochimiques et biophysiques de celui-ci, tandis que les modèles inverses permettent, à partir de la réflectance bidirectionnelle d'un milieu, de déduire les paramètres biochimiques et biophysiques qui modifient le signal électromagnétique. En télédétection spatiale, ce sont les modèles inverses qui sont utilisés pour observer les changements des surfaces terrestres et de l'atmosphère à partir des observations fournies par les capteurs de télédétection. Parmi ces modèles, on distingue les modèles de transfert radiatif des couverts des modèles de transfert radiatif des feuilles. Les modèles de transfert radiatif des couverts visent à modéliser les interactions entre le rayonnement électromagnétique et la structure du couvert végétal. On peut distinguer les modèles turbides, les modèles géométriques, et les modèles discrets [Kallel *et al.* 2007, Lecerf 2008]. Les modèles turbides et les modèles discrets étant les plus utilisés pour les applications de télédétection spatiale en milieu agricole. Parmi ceux-ci, on peut citer SAIL [Verhoef 1984] et DART [Gastellu-Etchegorry *et al.* 2008] qui appartiennent respectivement à la première et à la seconde catégories. Ces deux modèles représentent deux types de modélisation du paysage différents : l'un est un modèle dit « homogène » (SAIL), il représente le paysage par un simple profil vertical d'éléments absorbants ou diffusants [Jacquemoud *et al.* 2009]. L'autre modèle, DART, dit « hétérogène », représente le paysage par une distribution spatiale non uniforme d'éléments du paysage [Gastellu-Etchegorry *et al.* 2008]. Les modèles de transfert radiatif des feuilles permettent d'estimer les interactions entre le rayonnement électromagnétique et la structure des feuilles. Parmi les nombreux modèles existants, on peut citer PROSPECT qui est un modèle de couches (modèle turbide) où la feuille est considérée comme homogène et éclairée en lumière isotrope qui réfléchit, transmet et absorbe la lumière [Jacquemoud *et al.* 2006].

Pour modéliser la végétation en prenant en considération l'ensemble des éléments de la surface terrestre, il est nécessaire de coupler un modèle de transfert radiatif des feuilles avec un modèle de transfert radiatif des couverts. Cette opération permet d'obtenir une description des variations spectrales des couverts en fonction des paramètres biophysiques des plantes (teneur en chlorophylle, en eau, ...) et de l'architecture du couvert. Plusieurs couplages de modèles peuvent être envisagés. Le couplage des modèles PROSPECT et SAIL est très fréquemment utilisé, notamment pour effectuer une inversion sur des images satellites [Jacquemoud *et al.* 2009, Kallel *et al.* 2007, Bacour *et al.* 2006, Baret *et al.* 1992]. De plus, il a été validé avec des mesures de terrain dans plusieurs cas d'étude et les temps de calcul de ce modèle couplé sont assez courts comparés à d'autres tel que DART-PROSPECT [Jacquemoud *et al.* 2009, Lecerf 2008].

Une explication détaillée du couplage PROSAIL (PROSPECT+SAIL) et de leur fonctionnement est réalisée dans la section 1.4.1.1.3.2 (page 49) car il sera utilisé dans cette thèse pour estimer les variables biophysiques.

## 1.2.2.2. L'usage des images satellites acquises dans le domaine des hyperfréquences

### 1.2.2.2.1. La signature spectrale de la végétation

Le signal enregistré par les radars varie en fonction du capteur utilisé, de sa configuration (fréquence, polarisation, angle d'incidence) et des propriétés électriques et physiques de la surface observée. Dans les hyperfréquences (des bandes  $X$  à  $L$ , de  $2.4cm$  à  $30m$ ), le signal est sensible à l'humidité et à la rugosité des surfaces terrestres. Plusieurs mécanismes d'interaction entre le signal émis par le radar et le signal rétrodiffusé par le couvert végétal et le sol ont été identifiés (Figure 1.10) : la réponse du sol (diffusion de surface) se différencie de celle du couvert végétal (diffusion de volume) d'une part et de celle des surfaces mixtes couvertes en partie par du sol et en partie par de la végétation (diffusion double rebond) d'autre part [Lee & Pottier 2009].

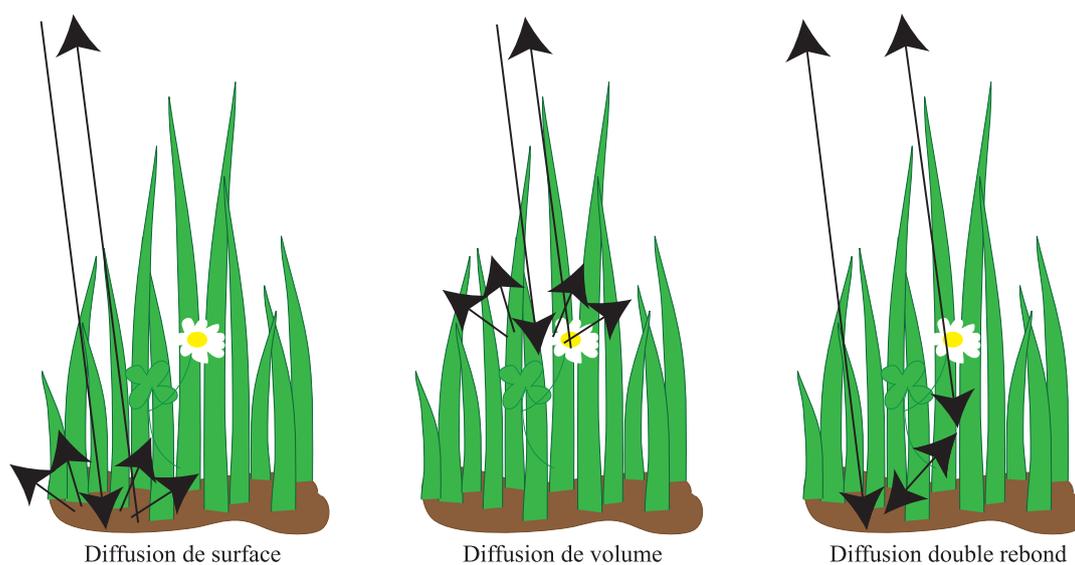


Figure 1.10 – Principaux mécanismes de rétrodiffusion sur un couvert végétal

Les coefficients de rétrodiffusion peuvent être obtenus selon plusieurs polarisations : les polarisations parallèles (HH, VV) et les polarisations croisées (HV, VH). Chaque polarisation permet d'avoir accès à un ou plusieurs paramètre(s) décrivant la végétation [McNairn & Brisco 2004]. La polarisation croisée, qui est sensible aux effets de diffusion de volume (hauteur et volume de la végétation) [Baghdadi *et al.* 2001, Ulaby & Elachi 1990] permet de discriminer les zones agricoles végétalisées et les surfaces forestières (parcelles en vert sur l'image RADARSAT-2 - figure 1.11). La polarisation parallèle, qui est plus sensible aux effets de diffusion de surface (réponse du sol) permet quant à elle de bien identifier les sols nus (parcelles en violet sur l'image RADARSAT-2 - figure 1.11).

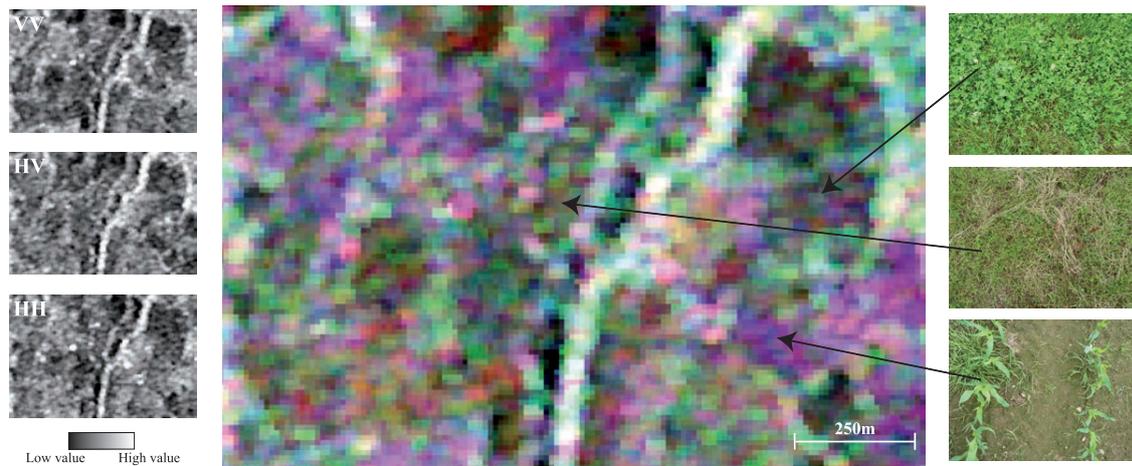


Figure 1.11 – Composition colorée d'un extrait d'une image RADARSAT-2 du 15/06/2010 à partir des intensités (VV (B), HV (V) et HH (R))

#### 1.2.2.2. Les données

Dans le domaine des hyperfréquences, la plupart des recherches menées en milieu agricole visent à identifier les cultures en utilisant des paramètres décrivant l'humidité et la rugosité de surface [McNairn & Brisco 2004]. Très peu d'études ont été menées sur l'identification des différents types de prairies et leur mode de gestion [Smith & Buckley 2011, Voormansik *et al.* 2013, Hill *et al.* 2005]. Les résultats obtenus dans ces études diffèrent sensiblement selon le mode de polarisation et la fréquence d'acquisition des données utilisées.

Les premières générations de capteurs radar, tels que ERS, JERS, RADARSAT-1, offrent une répétitivité temporelle intéressante pour le suivi de la croissance de la végétation, mais enregistrent le signal dans une polarisation unique, ce qui fait que les effets de l'humidité des sols et de morphologie de la couverture végétale ne sont pas distingués. Ainsi, s'il est possible de discriminer les cultures des prairies en utilisant plusieurs images [McNairn *et al.* 2002], des études réalisées à partir de plusieurs images RADARSAT-1 ont montré que ces dernières ne permettent ni de différencier différents types de prairies ni *a fortiori* d'identifier les pratiques agricoles avec ce type de données [Hill *et al.* 2000, Smith *et al.* 2006]. Il a été également observé que l'analyse de la corrélation entre les données SAR en polarisation simple acquises en bande C et l'état de surface des prairies n'est pas évidente car le signal rétro-diffusé des prairies est généralement faible quelque soit la hauteur de l'herbe [Voormansik *et al.* 2013, Herold *et al.* 2001]. Cependant, les études utilisant des données acquises en bande L ont montré une meilleure relation avec l'état de surface de la prairie et la hauteur de l'herbe [Hill *et al.* 1999a, Herold *et al.* 2001].

D'autres capteurs plus récents tels que PALSAR ou RADARSAT-2 permettent d'acquérir des données en polarisations parallèle et croisée (HH, VV, HV et VH), offrant ainsi davantage

de possibilités pour caractériser la végétation. Un radar polarimétrique renvoie neuf valeurs de rétrodiffusion pour chaque pixel (contre un seul pour un radar en polarisation simple), ce qui permet de séparer les informations provenant de la végétation de celles qui proviennent de l'humidité des sols [Hajnsek *et al.* 2009]. Ainsi, un intérêt particulier a été porté à ce type de données pour l'agriculture, l'identification et la cartographie des cultures pouvant être réalisées avec une seule image en polarisation croisée [McNairn *et al.* 2009, McNairn *et al.* 2000]. L'intérêt de ce type de données a aussi été souligné pour le suivi des couverts prairiaux [Smith & Buckley 2011, McNairn & Brisco 2004, Buckley 2004, Hill 2004]. Ainsi, des études ont mis en évidence les mécanismes de diffusion jouant sur les prairies en utilisant des données SAR en polarimétrie croisée en bande C : la diffusion de volume apparaît comme le mécanisme de diffusion dominant tandis que la diffusion de surface apparaît comme le mécanisme de diffusion secondaire [Hill *et al.* 2005, Luckman 1998]. D'autres études ont montré que la polarisation croisée en bande C est très intéressante pour identifier et délimiter les prairies de zones humides [Brisco *et al.* 2011, Touzi *et al.* 2007, Marechal *et al.* 2012], et y déterminer la densité de biomasse aérienne [Moreau & Le Toan 2003].

### 1.2.2.2.3. Les paramètres dérivés pour le suivi des prairies

#### 1.2.2.2.3.1. Les coefficients de rétrodiffusion ( $\sigma^0$ dB)

Les coefficients de rétrodiffusion, obtenus selon différentes polarisations, peuvent être utilisés pour caractériser la végétation. Les coefficients de rétrodiffusion en polarisations parallèles (HH, VV) sont plus sensibles aux effets de diffusion de surface, permettant ainsi d'identifier les sols nus alors que les coefficients de rétrodiffusion en polarisations croisées (HV, VH) sont plus sensibles aux effets de diffusion de volume, caractérisant les surfaces recouvertes par de la végétation [McNairn & Brisco 2004, Baghdadi *et al.* 2001]. Ainsi, le calcul de ratios polarimétriques (HH/HV, HH/VV ou HV/VV) permet de caractériser les surfaces végétales en identifiant le mécanisme de diffusion dominant (volume, surface ou double rebond), ce qui facilite leur identification [Ulaby & Dobson 1989].

#### 1.2.2.2.3.2. Les paramètres obtenus par décompositions polarimétriques

En plus des coefficients de rétrodiffusion, d'autres paramètres peuvent être dérivés des images radars polarimétriques pour caractériser la végétation [Cloude & Pottier 1997, Freeman & Durden 1998, Touzi 2007, Lee & Pottier 2009]. La méthode utilisée pour extraire ces paramètres est basée sur la décomposition du signal en différents mécanismes de rétrodiffusion (Figure 1.10).

Plus précisément, Cloude et Pottier [Cloude & Pottier 1997] ont développé une méthode purement statistique, basée sur la décomposition en valeurs propres de la matrice de cohérence, pour mettre en évidence la contribution des différents mécanismes de diffusion présents dans l'image (Figure 1.10). Trois paramètres sont ainsi extraits : l'entropie polarimétrique notée  $H$ , l'anisotropie polarimétrique notée  $A$  et l'angle  $\alpha$ . Le paramètre d'entropie  $H$  représente le caractère aléatoire des mécanismes de diffusion présents dans les pixels. S'il est égal à 0, alors un seul mécanisme de diffusion est présent (pour une surface en eau par exemple) ; s'il est égal à 1, alors plusieurs mécanismes de diffusion aléatoires sont présents (dépolarisation du signal par la cible, pour une surface forestière par exemple). Le paramètre d'anisotropie  $A$

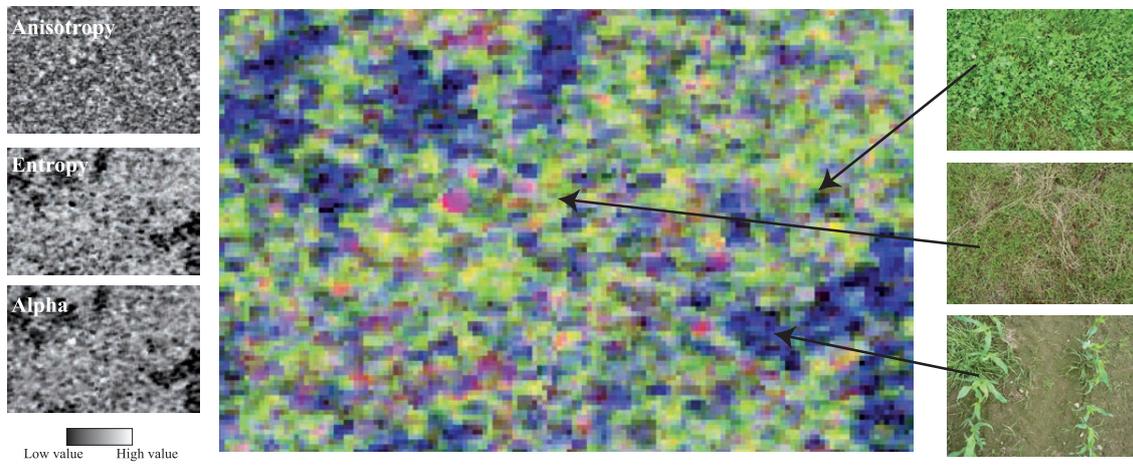


Figure 1.12 – Composition colorée d’un extrait d’une image RADARSAT-2 du 15/06/2010 à partir des paramètres polarimétriques de Cloude-Pottier (Anisotropy (B), Entropy (V) et Alpha (R))

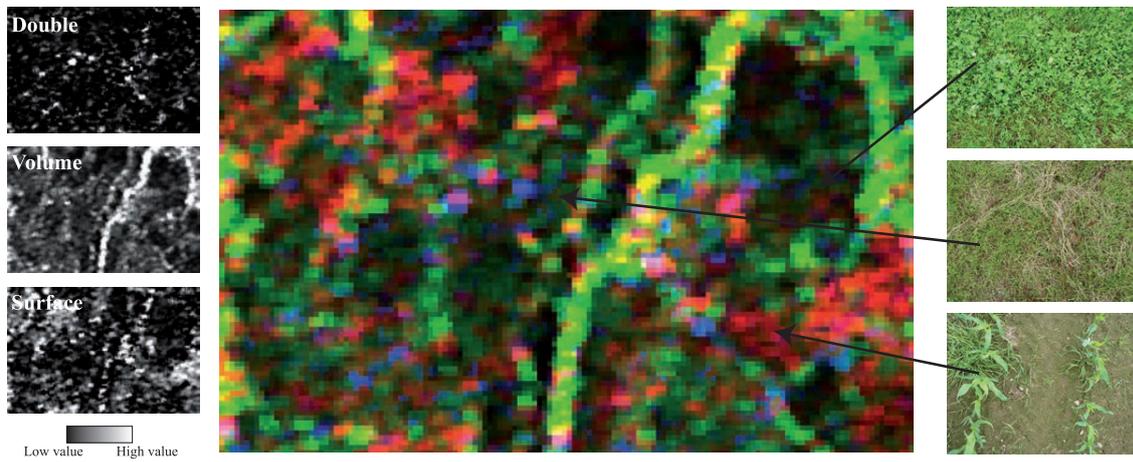


Figure 1.13 – Composition colorée d’un extrait d’une image RADARSAT-2 du 15/06/2010 à partir des paramètres polarimétriques de Freeman-Durden (Double (B), Volume (V) et Surface (R))

identifie l'importance des mécanismes de diffusion secondaires. S'il est égal à 0, alors les deux mécanismes ont des proportions égales ; s'il est égal à 1, alors le second mécanisme domine. L'angle  $\alpha$  renseigne sur le mécanisme de diffusion présent dans les pixels : une diffusion de surface est caractérisée par un angle égal à  $0^\circ$ , une diffusion dipolaire ou de volume par un angle égal à  $45^\circ$  alors qu'une diffusion multiple est associée un angle égal à  $90^\circ$ . La combinaison des images illustrant ces trois paramètres est illustrée par la figure 1.12. Ainsi, le paramètre d'anisotropie, ici associé à la couleur bleu, correspond à des parcelles de sols nus à peu couverts ; le paramètre d'entropie, associé à la couleur verte, correspond aux surfaces couvertes par de la végétation de types agricoles ou forestières et le paramètre alpha, associé à la couleur rouge, correspond aux surfaces artificialisées (très peu représentées sur cette image).

Freeman et Durden [Freeman & Durden 1998] ont développé une autre méthode pour séparer les différents mécanismes de diffusion présents dans l'image (Figure 1.10). Cette méthode, basée sur la modélisation simple d'un volume aléatoire, permet ainsi de discriminer trois mécanismes de diffusion : la diffusion de surface qui caractérise généralement les sols nus à peu couverts ; la diffusion de volume qui décrit principalement les surfaces végétalisées et forestières ; la diffusion à double réflexion (double rebond) associée aux surfaces urbanisées. La combinaison des images illustrant ces trois mécanismes est illustrée par la figure 1.13. Les images de diffusion de volume et de surface mettent respectivement bien en évidence les surfaces couvertes par de la végétation de celles en sols nus à peu couverts.

### 1.2.3. Classification de séries temporelles de données de télédétection

Des séries temporelles de paramètres issus de données de télédétection acquises par des capteurs à haute répétitivité temporelle comme MODIS ou les futurs capteurs Sentinel et Venus peuvent être utilisées pour identifier les prairies et leurs modes de gestion. Cela nécessite, d'une part, de sélectionner les paramètres les plus pertinents parmi l'ensemble de ceux qu'il est possible de dériver des images de télédétection (indices de végétation, variables biophysiques, paramètres polarimétriques, etc.) et d'autre part, d'effectuer une classification des profils temporels de ces paramètres.

#### 1.2.3.1. Les profils temporels

L'évolution intra-annuelle des profils temporels des paramètres dérivés des données de télédétection illustre la croissance de la végétation en mettant en évidence les stades phénologiques des cultures. Ces profils varient selon la localisation du site d'étude (hémisphère nord *versus* hémisphère sud) et les conditions climatiques.

La figure 1.14-a illustre l'évolution intra-annuelle théorique de la variable biophysique LAI pour différents couverts végétaux dans un site caractérisé par un climat tempéré situé dans l'Ouest de la France, en Bretagne. Elle met en évidence les périodes de semis, de développement de la végétation (augmentation progressive des valeurs de LAI) et de récolte (forte baisse des valeurs de LAI). Si, pour différentes parcelles appartenant à un même type d'oc-

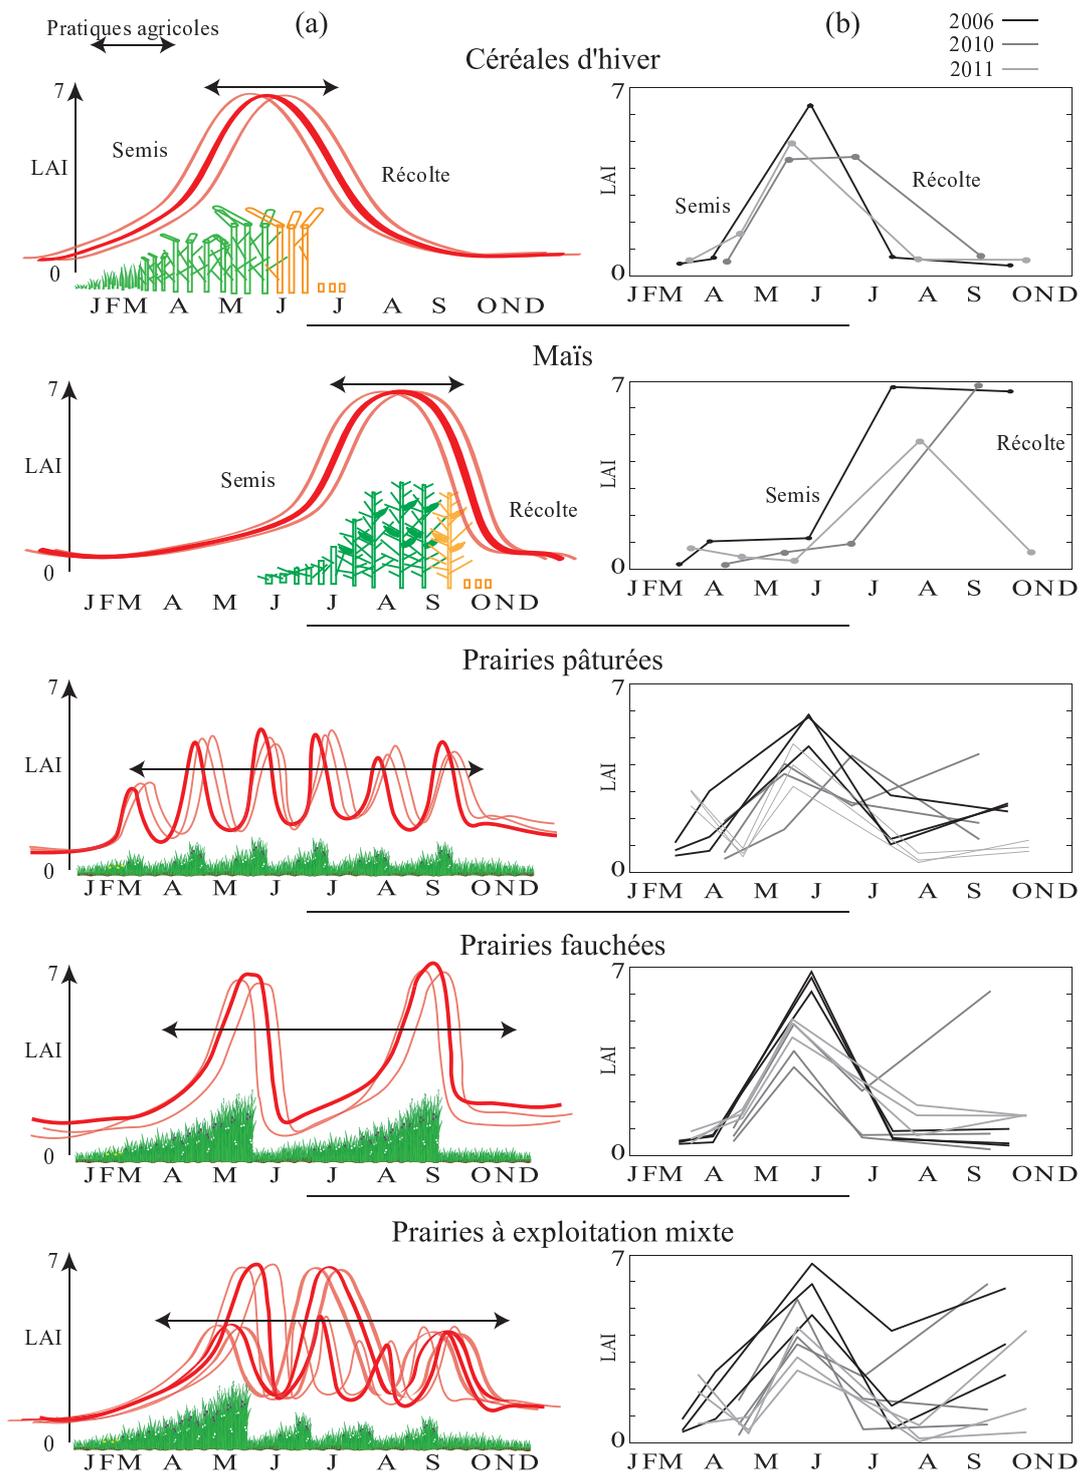


Figure 1.14 – Exemples de profils temporels intra-annuels pour des parcelles de céréales d’hiver, de maïs, et de prairies utilisées pour du pâturage, en fauche et en exploitation mixte (a) théoriques et (b) dérivés de séries d’images satellites optiques acquises en 2006, 2010 et 2011

cupation du sol, l'évolution des profils est globalement similaire, un décalage dans le temps peut s'observer en fonction des pratiques agricoles réalisées sur ces parcelles (dates de semis, conditions climatiques, etc.). Les prairies sont caractérisées par une grande diversité de profils temporels intra-annuels selon les modes de gestion réalisés. Les principales pratiques (pâturage, fauche, exploitation mixte) présentent des profils très contrastés dont la forme reflète la fréquence des actions réalisées sur les parcelles : les prairies sont pâturées tous les 30 à 40 jours alors qu'elles ne sont fauchées que tous les 50 jours au minimum. Ainsi, les modes de gestion peuvent être identifiés à partir de l'analyse des valeurs de LAI au cours de la saison végétative.

La figure 1.14-b illustre les séries temporelles extraites de données de télédétection à haute résolution spatiale acquises sur le même site au cours de trois années. Ces séries sont composées de 4 à 5 images au cours de la saison végétative, synthétisant ainsi l'information temporelle de l'évolution de la végétation. Les périodes de semis, de développement de la végétation et de récolte s'identifient aisément sur les profils de céréales d'hivers et de maïs. On observe aussi que les profils des prairies contrastent fortement avec ceux des cultures et ce quelque soit l'année considérée. En revanche, les profils illustrant les différentes pratiques agricoles au sein des prairies sont plus proches.

En théorie, la distinction prairies/cultures et l'identification des modes de gestion des prairies est aisément réalisable avec des séries temporelles comme le montrent les profils temporels de la figure 1.14-a. En pratique, avec l'utilisation d'un nombre limité d'images (moins d'une dizaine, cf. figure 1.14-b), si la distinction prairies/cultures apparaît toujours aisée à effectuer, il en va autrement du mode de gestion des prairies dont les profils temporels sont en même temps très variables et pour partie confondus.

### 1.2.3.2. Analyse de la séparabilité entre les classes

Nous avons vu précédemment que de nombreux paramètres peuvent être dérivés des données de télédétection optiques et radars (indices de végétation, variables biophysiques, coefficients de rétrodiffusion, paramètres polarimétriques, etc.).

Cependant, plusieurs études ont montré que la précision d'une classification n'augmente pas proportionnellement avec le nombre de variables utilisées, elle peut même être réduite [Van Niel *et al.* 2005, Bruzzone & Serpico 2000]. Ainsi, il est important de sélectionner les paramètres les plus pertinents avant de réaliser les classifications. Pour cela, des tests basés sur la mesure d'une distance de séparabilité entre les classes peuvent être utilisés. Ces tests statistiques permettent de mesurer la capacité d'un paramètre à discriminer deux classes différentes. Dans le domaine de la télédétection, la distance euclidienne, la distance de Mahalanobis, la distance M-statistic, la divergence, la divergence transformée, la distance de Jeffries-Matusita et la distance de Bhattacharyya sont les plus couramment utilisées pour mesurer la séparabilité entre classes [Richards 2012, Van Niel *et al.* 2005, Bruzzone & Serpico 2000, Swain & King 1973, Thomas *et al.* 1987].

Dans le cadre des séries temporelles, la distance euclidienne calcule la séparabilité entre deux classes en comparant les différences date par date des valeurs des paramètres (valeurs moyennes des classes) alors que les autres mesures s'appuient aussi sur les distributions des valeurs, permettant par exemple de prendre en compte la variance. Certaines de ces méthodes calculent la séparabilité entre deux classes d'une seule variable (la distance euclidienne, la distance de Mahalanobis, la distance M-statistic) tandis que les autres permettent de mesurer la séparabilité entre deux classes en utilisant plusieurs variables à la fois. Certaines de ces mesures (la distance euclidienne, la distance de Mahalanobis, la distance M-statistic, la divergence et la distance de Bhattacharyya) ne possèdent pas de bornes minimum et maximum : l'indice de séparabilité augmente tant que la distance entre la moyenne des classes progresse même quand le seuil de 100% de séparabilité est atteint. *A contrario*, la divergence transformée et la distance de Jeffries-Matusita possèdent des bornes minimum et maximum. Par contre, il a été montré que ces deux dernières mesures ont tendance à maximiser les valeurs de distance quand la séparabilité est faible et à les minimiser quand la séparabilité est forte [Thomas *et al.* 1987]. Ainsi, en fonction du jeu de données considéré, la méthode la plus adaptée n'est pas identique. La distance euclidienne sera utilisée pour comparer des données univariées (un seul paramètre à comparer) alors que la divergence transformée, plus simple à calculer que la distance de Jeffries-Matusita, sera utilisée pour comparer des données multivariées (plusieurs paramètres à comparer).

### 1.2.3.3. Classification de séries temporelles

La classification a pour but de regrouper dans des classes les objets (ou pixels) ayant des caractéristiques similaires. Les méthodes de classification peuvent être séparées en deux groupes : les méthodes supervisées et les méthodes non supervisées, c'est-à-dire, avec ou sans l'utilisation de données d'apprentissage. Ainsi, les méthodes supervisées sont basées sur l'utilisation d'un échantillonnage collecté au préalable par l'utilisateur au cours de campagnes de terrain par exemple, pour séparer et classer les objets.

Jusqu'à ces dernières années, la plupart des méthodes utilisées en télédétection pour classer des séries temporelles ont assimilé la série à une donnée multivariée (chaque série temporelle étant représentée par un vecteur de paramètres). L'image résultante, multivariée, est alors classée avec des outils génériques sans prise en compte de l'aspect temporel [Bruzzone *et al.* 1999, Millward *et al.* 2006, Schuster *et al.* 2015, Esch *et al.* 2014, Hao *et al.* 2014, Brown *et al.* 2013, Arvor *et al.* 2011, Wardlow & Egbert 2008]. De nombreuses stratégies existent pour classer des données allant des algorithmes les plus communs basés sur le calcul de distances (par exemple la théorie des plus proches voisins) ou de probabilités (par exemple le maximum de vraisemblance) à des techniques plus avancées dédiées aux données complexes (par exemple les algorithmes utilisant les textures) [Liu & Fieguth 2012, Sahbi *et al.* 2011, Ojala *et al.* 2002] ou projetant les données dans des espaces transformés pour mieux gérer des séparations complexes entre les classes [Zhang *et al.* 2007, Camps-Valls *et al.* 2006, Scholkopf & Smola 2001].

D'autres techniques utilisent partiellement l'aspect temporel des séries de données de té-

lédétection en calculant des critères entre images successives (radiométrie, texture) afin de mettre en évidence des motifs temporels [Lefebvre *et al.* 2009, Inglada & Mercier 2007, Bruzzone & Prieto 2000, Lambin & Strahlers 1994]. Enfin, certains auteurs ont également travaillé sur l'identification et l'analyse de motifs fréquentiels apparaissant dans les séries temporelles d'images satellites en utilisant les transformées de Fourier ou les ondelettes [Celik & Ma 2011, Julea *et al.* 2011, Petitjean *et al.* 2010, Julea *et al.* 2008, Andres *et al.* 1994].

Bien que performantes, ces approches ne sont pas optimales dans le cas de séries temporelles d'images de télédétection, notamment d'images optiques, celles-ci étant souvent hétérogènes et incomplètes en raison de la présence de nuages principalement. De plus, dans ces méthodes, l'information temporelle est indirectement prise en compte et aucune ne s'attache à la comparaison directe de séries temporelles.

L'exploitation de séries temporelles possède l'intérêt de mettre en évidence des motifs temporels caractéristiques de chaque classe. Cependant, les critères de comparaison de séries mentionnés ci-dessus ne sont pas optimaux pour mettre en évidence des motifs identiques, même si ceux-ci sont décalés dans le temps ou à des échelles différentes (deux séries temporelles peuvent être temporellement corrélées -et donc considérées comme appartenant à la même classe- même si elles sont décalées dans le temps). Ainsi, dans le domaine de la classification de séries temporelles, et notamment en préparation des futures missions d'observation spatiales d'observation de la terre Sentinel-2 et Venµs, plusieurs études se sont intéressées à la conception de métriques pour comparer plus judicieusement deux séries temporelles, ici notées  $\mathbf{t}_1 = [t_{11}, \dots, t_{1N}]^T$  et  $\mathbf{t}_2 = [t_{21}, \dots, t_{2N}]^T$ . En effet, des études ont montré que les métriques usuelles telle que la norme  $L2$  sont peu adaptées pour la comparaison de données temporelles et tandis que des métriques dites « élastiques », cherchant à déformer les séries d'entrées pour mieux les mettre en correspondance, produisent de meilleurs résultats [Keogh & Ratanamahatana 2005]. Dans ce contexte, la déformation temporelle dynamique (algorithme DTW pour Dynamic Time Warping), métrique temporelle introduite il y a vingt ans pour la comparaison de signaux audio [Berndt & Clifford 1994], présente des solutions intéressantes pour la classification de séries temporelles d'images de télédétection. En effet, DTW mesure la similarité entre deux séries pouvant varier dans le temps et cherche une correspondance optimale entre ces deux séries. Le principe de base consiste à trouver un chemin minimisant la distance entre les deux séries (détails dans le chapitre 4.1). Cette métrique constitue une solution intéressante dans le contexte des séries temporelles de télédétection. DTW a déjà été largement utilisée pour la classification, le regroupement ou la détection de points aberrants dans divers domaines telles que la reconnaissance vocale, l'analyse génétique ou la reconnaissance de texte, etc [Zhang *et al.* 2010, Marteau 2009, Keogh & Ratanamahatana 2005, Tomasi *et al.* 2004, Deller *et al.* 1993]. Cependant, mis à part quelques études récentes [Petitjean *et al.* 2012, Petitjean *et al.* 2011], DTW n'est encore que peu exploitée dans le domaine de la télédétection.



## 1.3. Le site d'étude

### 1.3.1. Caractéristiques du bassin versant du Yar

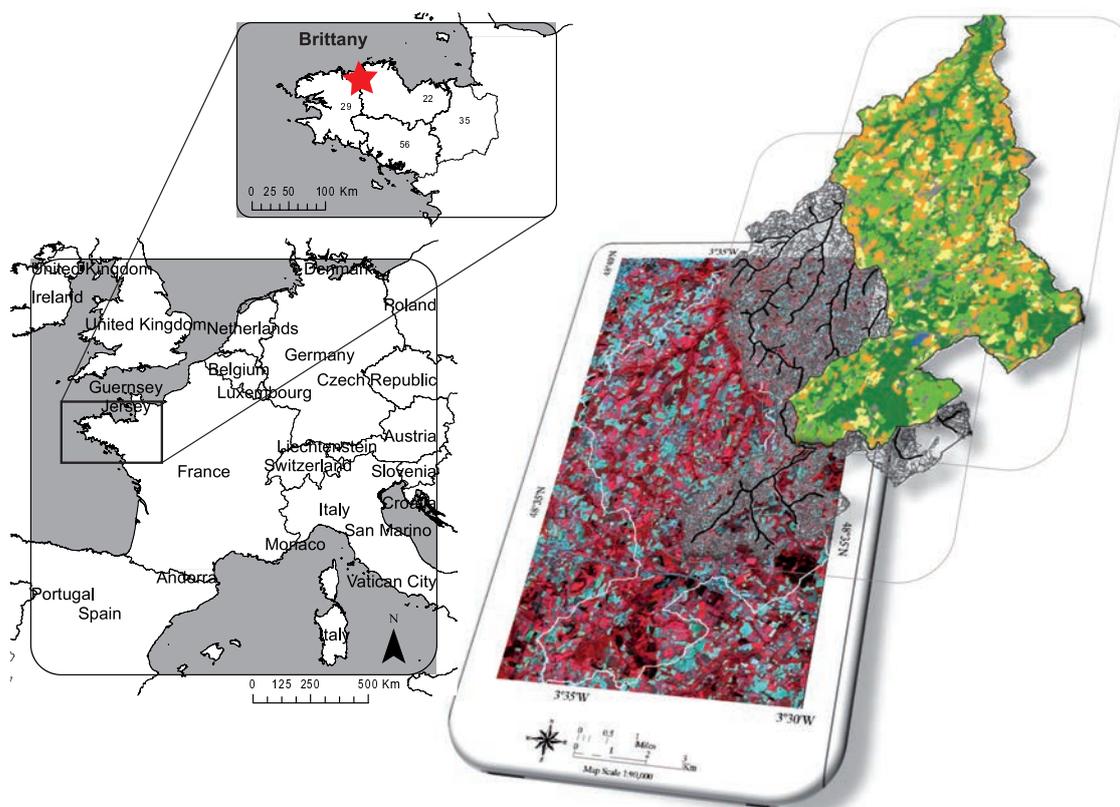


Figure 1.15 – Localisation du site d'étude

Le site d'étude retenu est le bassin versant du Yar (Figure 1.15). D'une superficie de  $61.5 \text{ km}^2$  et localisé sur le littoral nord de la Bretagne à l'ouest du département des Côtes d'Armor, ce site est caractérisé par un climat océanique tempéré avec des hivers doux et des étés frais, une forte humidité et une couverture nuageuse relativement importante au cours de l'année (Figure 1.16).

Il fait partie des bassins versants côtiers situés en amont de la Baie de Lannion (Saint Michel-en-Grève) très touchée par le développement des algues vertes (marées vertes) depuis plusieurs années (Figure 1.17). En effet, des taux élevés d'azote dans les eaux des rivières, en grande partie dus à la régression des surfaces en prairies et une fertilisation accrues des

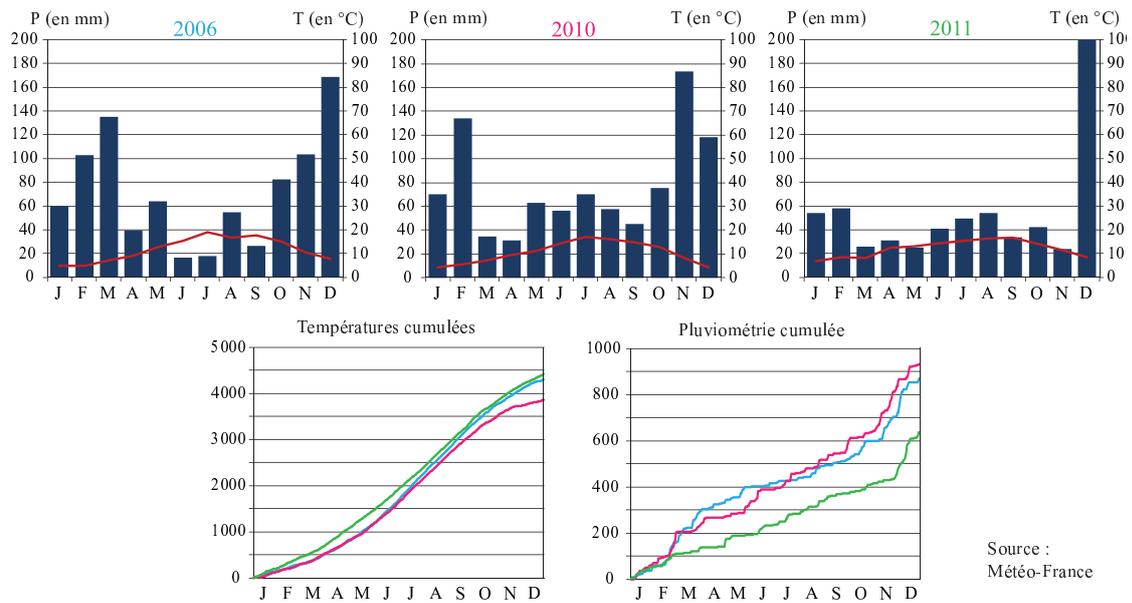


Figure 1.16 – Diagrammes ombrothermiques de la région du bassin versant du Yar des trois années étudiées

cultures, ont été observés depuis plusieurs années sur ce site [Moreau *et al.* 2013]. La baie de Saint Michel-en-Grève (exutoire du Yar) est très confinée et les courants y sont très faibles, ce qui empêche les eaux douces provenant des rivières de se mélanger avec les eaux de la mer. De plus, les fonds marins sont très peu profonds, ce qui favorise un réchauffement rapide des eaux au printemps et en été et donc le développement et la prolifération d'algues vertes. Ainsi, la morphologie de la baie accentue les problèmes environnementaux liés à l'activité agricole présente sur le site.



Figure 1.17 – Illustration du développement des algues vertes sur l'espace côtier de la Baie de Saint Michel-en-Grève

Majoritairement agricole et essentiellement orienté vers l'élevage bovin, il comprend une grande proportion de prairies (60% environ de la SAU) situées pour une part d'entre elles en zone humide (prairies permanentes), les autres étant insérées dans des systèmes cultureux (prairies temporaires/artificielles) (biologique, conventionnel, ...). Les prairies de ce site sont

gérées selon divers modes comme le pâturage, la fauche, l'exploitation mixte (combinaison du pâturage et de la fauche sur une même parcelle), la fertilisation, le retournement. Près de 55% des prairies sont principalement pâturées, 5% sont fauchées exclusivement et 40% étant exploitées de façon mixte. Ce bassin versant est ainsi représentatif de la grande variété de pratiques agricoles associées aux prairies de l'Ouest de la France.

Ce site a déjà fait l'objet de nombreuses études par télédétection tant sur la partie littorale pour effectuer un suivi des algues vertes, que sur la partie continentale afin de mettre en évidence les modes d'occupation et d'utilisation des sols et les pratiques agricoles qui influent sur le transfert de flux de polluants, telles que l'implantation de couverts hivernaux [Corgne 2004] et le drainage des zones humides [Hubert-Moy *et al.* 2005]. Ainsi, une grosse base de données permettant de retracer son évolution paysagère est disponibles sur ce site. Si les modes de gestion ne sont pas accessibles par cette base de données, en revanche elle permet de reconstituer l'évolution des prairies depuis les années 50 sur le site et d'identifier les retournements de prairies depuis les années 90.

### **1.3.2. Historique de l'occupation des sols sur le bassin versant du Yar pour déterminer la place des prairies dans les systèmes de production**

Deux trajectoires temporelles d'occupation des sols sur le bassin versant du Yar ont été reconstituées afin de retracer l'évolution de la place des prairies dans les systèmes de production depuis les années 50 : la première à partir de photographies aériennes de l'IGN<sup>©</sup> prises avec un pas de temps de quinze ans environ sur une période allant de 1952 à 2008 (« temps long »), la deuxième a été réalisée à partir d'images satellites prises annuellement sur une période allant de 1997 à 2008 (« temps court »). Ces trajectoires ont été reconstituées à l'échelle parcellaire.

#### **1.3.2.1. Évolution des prairies sur le bassin versant du Yar depuis les années 1950 (« temps long : de 1952 à 2008 »)**

##### **1.3.2.1.1. Les données**

Les données utilisées pour l'analyse de la dynamique spatio-temporelle de l'occupation des sols à l'échelle parcellaire sur le « temps long » sont des cartographies de l'occupation des sols du bassin versant du Yar pour les années 1952, 1978, 1998 et 2008. Ces cartographies ont été réalisées à partir de classifications par photo-interprétation assistée par ordinateur de photographies aériennes caractérisées par une résolution spatiale de 0.5cm. La figure 1.18 illustre l'évolution de l'occupation des sols sur le bassin versant du Yar entre 1952 et 2008. En dehors des prairies, les surfaces boisées, les surfaces en eau, les surfaces urbanisées et les cultures ont été identifiées et cartographiées.

##### **1.3.2.1.2. Analyse de la dynamique spatio-temporelle de l'occupation des sols**

Le croisement des quatre cartes dans un Système d'Information Géographique (SIG) a permis de mettre en évidence l'évolution des couverts prairiaux sur le bassin versant. Même si les surfaces en prairie dominent toujours en 2008 sur la zone d'étude, une très nette diminution

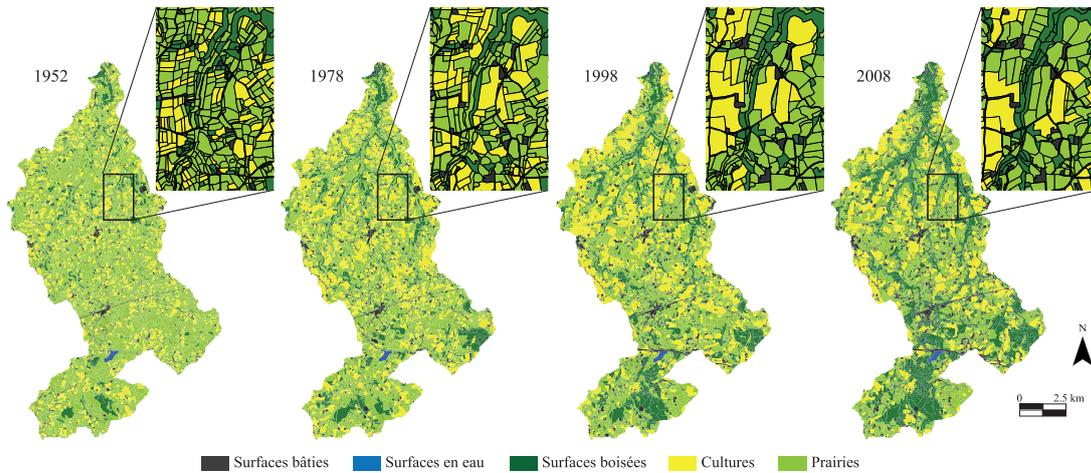


Figure 1.18 – Cartes de l'occupation des sols sur le bassin versant du Yar en 1952, 1978, 1998 et 2008

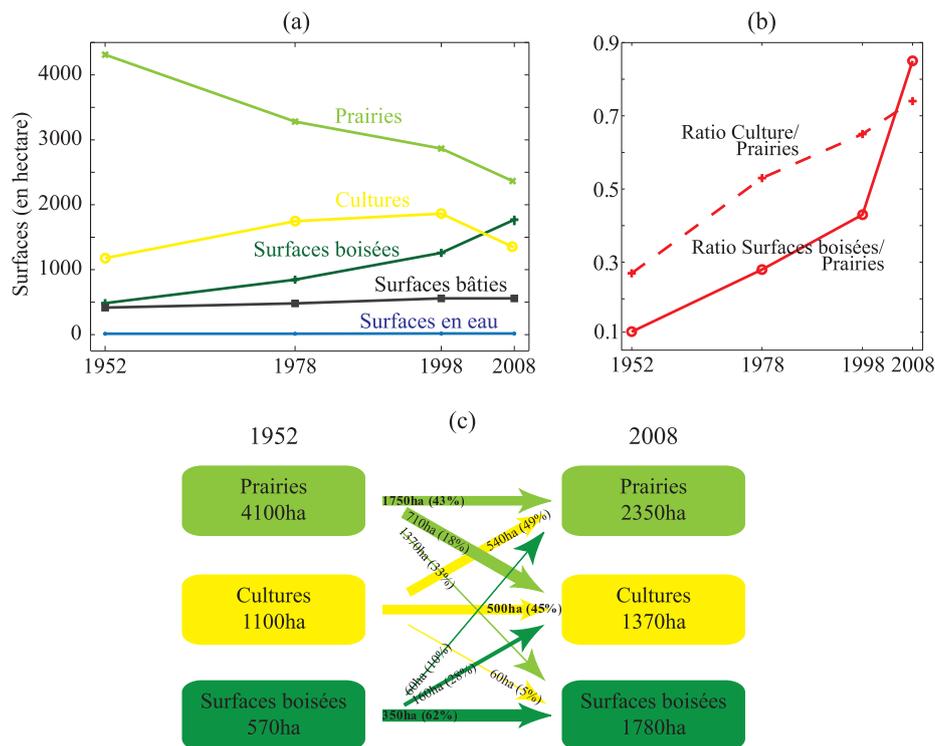


Figure 1.19 – Principaux changements d'occupation des sols sur le bassin versant du Yar entre 1952 et 2008 : évolution en surfaces de l'occupation des sols (a), évolution des ratios Cultures/Prairies et Surfaces boisées/Prairies (b) et dynamique temporelle des surfaces en prairies, cultures et surfaces boisées (c)

(de presque 60%) peut être observée, leur surface totalisant 4100 hectares (*ha*) environ en 1952 contre 2350*ha* environ en 2008, principalement au détriment des surfaces boisées et des surfaces en culture. En effet, en 1952, près de 67% du bassin versant était occupé par des prairies contre 35% en 2008. À l'inverse, les surfaces boisées passent de 7% en 1952 à près de 30% en 2008, en grande partie en raison de la plantation de conifères enclenchée par des politiques incitant à la sylviculture. Parallèlement à cette évolution, le nombre de parcelles en prairie a été divisé par trois, passant de près de 8000 en 1952 à 3000 en 2008. Ceci s'est traduit par une hausse continue de la taille des parcelles, leur surface moyenne étant passée en 56 ans de 0.5*ha* à 0.7*ha* (Figure 1.18). Dans une moindre mesure, la baisse des prairies s'explique aussi par la progression des cultures. En effet, si les cultures ont sensiblement augmenté entre 1952 et 1998 (de 8 à près de 10%), celles-ci ont tendance à légèrement diminuer dans la dernière partie de la période d'étude entre 1998 et 2008 (de -1% de la surface totale du bassin versant). Les surfaces bâties ont, elles, légèrement augmenté, passant de 7% en 1952 à 11% en 2008. Enfin, les surfaces en eau sont restées stables sur toute la période (0.3% de la surface totale du bassin versant) (Figure 1.19-a). L'analyse des ratios Cultures/Prairies et Surfaces boisées/Prairies montre qu'entre 1952 et 2008 les surfaces en prairie ont nettement diminué au détriment des cultures et des surfaces boisées, qui ont augmenté respectivement de 40% et près de 80% (Figure 1.19-b).

Au-delà de la baisse des surfaces occupées par les prairies sur le bassin versant, le croisement des cartes à l'aide d'un SIG permet de mettre en évidence leur dynamique spatio-temporelle (Figure 1.19-c). Ainsi, seules 43% des parcelles en prairies en 1952 étaient toujours en prairie en 2008, alors que 23% des prairies de 2008 correspondent à des parcelles qui étaient cultivées en céréales en 1952 et 2.5% à des boisements. De plus, la baisse des surfaces en prairies n'a pas épargné les zones humides de fonds de vallée : les prairies occupaient environ 80% de la superficie de ces dernières en 1952, contre seulement 30% environ en 2008, illustrant le processus d'enfrichement puis de boisement qui a caractérisé ces milieux depuis les années 70.

### 1.3.2.2. Les prairies sur le bassin versant du Yar depuis la fin des années 1990 (« temps court : de 1997 à 2008 »)

#### 1.3.2.2.1. Les données

Les données utilisées pour (1) l'analyse des successions culturales et (2) l'analyse de la dynamique spatio-temporelle des prairies à l'échelle parcellaire sur le « temps court » sont des cartographies annuelles de l'occupation des sols du bassin versant du Yar pour les années 1997 à 2008 (Figure 1.20). Ces cartographies ont été réalisées à partir du traitement d'une série d'images satellitaires : deux images ont été acquises par an, une en été et une en hiver, sur la période 1997-2008 par des capteurs dont la résolution spatiale varie entre 30*m* et 1*m* (Landsat, SPOT, IRS-LISS, GeoEye...). Les images satellites ont d'abord été géoréférencées et corrigées des effets de l'atmosphère pour les rendre comparables entre elles. Après avoir été pré-traitées, les images ont été classées individuellement en six catégories d'occupation des sols : les surfaces bâties, les surfaces en eau, les surfaces boisées, les céréales, le maïs et les prairies. Les classifications ont été effectuées de façon supervisées. Ainsi, des mesures et observations effectuées chaque année sur le terrain à l'échelle parcellaire, telles que le

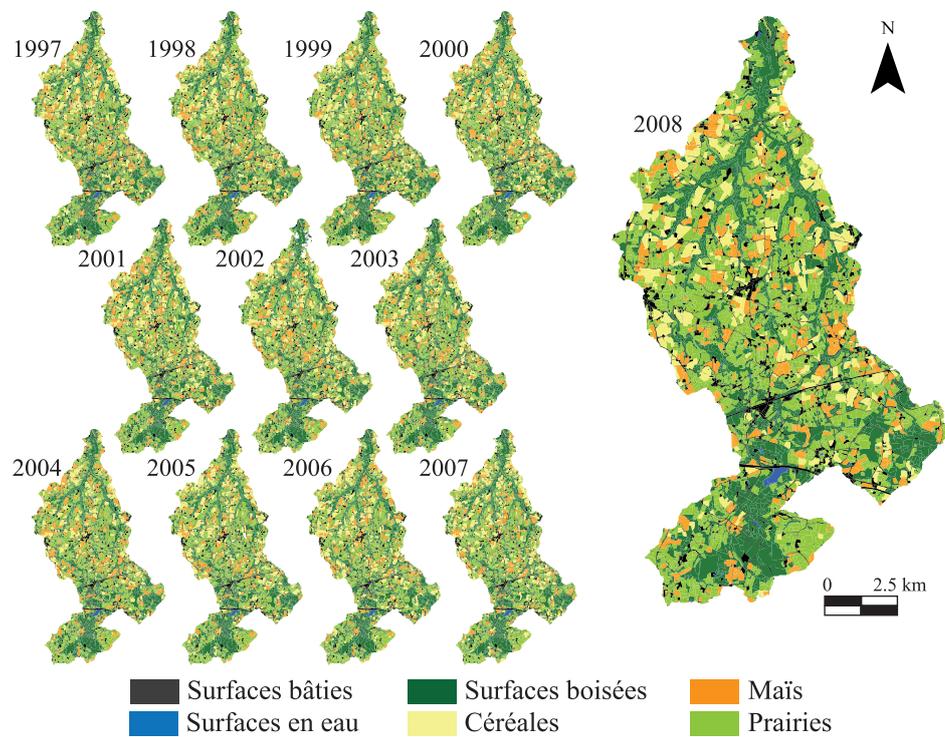


Figure 1.20 – Cartes de l'occupation des sols sur le bassin versant du Yar de 1997 à 2008

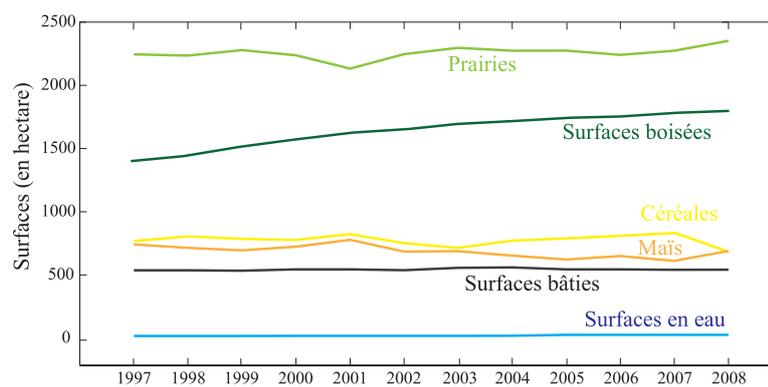


Figure 1.21 – Évolution des changements d'occupation des sols entre 1997 et 2008 sur le bassin versant du Yar

type d'occupation des sols, le taux de couverture des sols par la végétation, la hauteur de la végétation, ou des mesures spectroradiométriques ont été utilisées pour calibrer et valider les classifications. Ces dernières ont ensuite été post-traitées dans un SIG afin de déterminer les successions culturales à l'échelle parcellaire. Ainsi, les successions dites improbables ou impossibles sur le plan agronomique et en terme de dynamique de l'occupation des sols ont été corrigées manuellement par requêtes SIG afin de supprimer les erreurs d'affectation de classes.

### 1.3.2.2.2. Analyse des successions culturales et de la dynamique spatio-temporelle des prairies

L'analyse de l'évolution de l'occupation des sols sur la période 1997–2008 montre que les surfaces en eau et les surfaces bâties apparaissent stables. Les surfaces boisées ont, elles, légèrement augmenté (+5% de la surface totale du bassin versant). En ce qui concerne la Surface Agricole Utile (SAU), la répartition des cultures et des prairies est stable, des tendances à la hausse ou à la baisse n'étant pas observables sur la période d'étude. Toutefois, des variations inter-annuelles sont observées en fonction des itinéraires techniques choisis par les agriculteurs et des législations en vigueur. Les surfaces en prairie dominent à l'échelle du bassin versant et de la SAU (respectivement 35% de la surface totale et environ 60% de la SAU), tandis que le maïs et les céréales occupent une proportion similaire de la SAU (10% de la surface totale et environ 20% de la SAU pour chaque type de culture) (Figure 1.21).

L'extraction des successions culturales a été réalisée à partir de la base de données annuelle de l'occupation des sols de 1997 à 2008 (« temps court »). Les polygones correspondant à la SAU ont été conservés et séparés en deux classes : prairies et cultures qui comprennent les céréales d'hiver et le maïs. Les successions ont été ensuite définies par concaténation des informations d'occupation des sols de toutes les années considérées (Tableau 1.3).

Tableau 1.3 – Exemples de successions culturales extraites de la base de données de l'occupation des sols pour la trajectoire « temps court » 1997-2008

1997	1998	1999	2000	2001	2002	2003	2004	2005	2006	2007	2008	Concatenation
P	P	P	P	P	P	P	P	P	P	P	P	PPPPPPPPPPPP
C	C	C	C	C	C	C	C	C	C	C	C	CCCCCCCCCCCC
P	P	P	C	C	P	P	P	P	P	P	C	PPCCPPPPPPPC
P	P	C	C	C	C	C	P	P	P	P	P	PCCCCCPPPPPP
P	P	P	P	P	P	P	P	P	C	C	P	PPPPPPPPCCCP
...	...	...	...	...	...	...	...	...	...	...	...	...

Afin d'analyser la dynamique spatio-temporelle des prairies, deux indicateurs ont été utilisés : le nombre d'années d'une parcelle en prairie *versus* le nombre d'années d'une parcelle en culture sur la période 1997-2008 (Figure 1.22-a1) et le nombre d'années successives maximale d'une parcelle en prairie *versus* le nombre d'années successives maximale d'une parcelle en culture sur la période 1997-2008 (Figure 1.22-b1). Ainsi, l'analyse de la fréquence d'occurrence des prairies et des cultures montre que presque 30% des parcelles ont été couvertes par des prairies sur les douze années étudiées alors qu'environ 10% seulement n'ont jamais été en prairie (Figure 1.22-a1). De plus, l'analyse de la fréquence d'occurrence des prairies et des cultures successives met en évidence qu'en dehors des parcelles étant restées en prairie

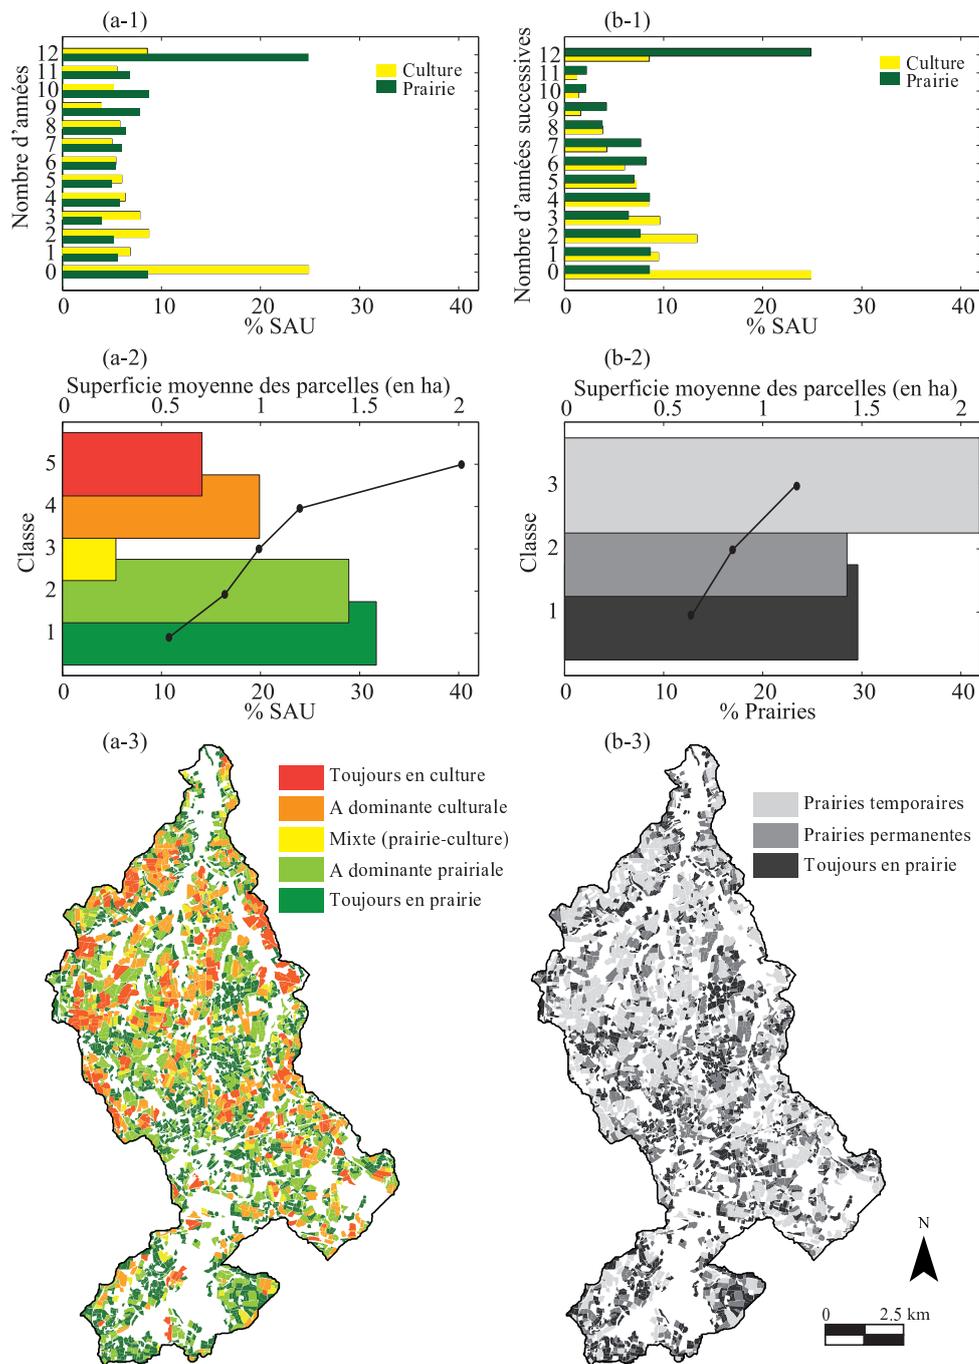


Figure 1.22 – Les dynamiques spatio-temporelles de la SAU à l'échelle parcellaire : fréquence de retour des prairies et des cultures sur la période 1997-2008 sur le bassin versant du Yar non successives (a) et successives (b). [Nombre d'années en prairies et en cultures sur la période 1997-2008 (a-1), classement des parcelles selon les types de successions culturales (a-2), cartographie des types de successions culturales (a-3), nombre d'années en prairies et en cultures successives sur la période 1997-2008 (b-1), classement des prairies selon leur durée (b-2) et cartographie (b-3)]

pendant douze ans, les prairies ayant des durées de 4 à 6 ans sont les plus représentées (de 8 à 10%).

D'après ces indicateurs, deux classements ont été réalisés : un premier sur les types de successions culturales rencontrées sur le bassin versant basé sur le nombre d'années en prairie et en culture (Figure 1.22-a2) ; un deuxième sur les prairies et leur durée basé sur le nombre d'années successives en prairie (Figure 1.22-b2).

Ainsi, cinq classes de successions culturales ont été identifiées :

- La classe 1 représente les parcelles ayant toujours été en prairie sur la période 1997-2008 (11 à 12 années en prairies) ;
- La classe 2 représente les parcelles à dominante prairiale comprenant les parcelles ayant été en prairie pendant 7 à 10 années sur la période 1997-2008 ;
- La classe 3 représente les parcelles mixtes comprenant les parcelles ayant été 6 années en prairie et 6 années en culture sur la période 1997-2008 ;
- La classe 4 représente les parcelles à dominante culturale comprenant les parcelles ayant été en culture pendant 7 à 10 années sur la période 1997-2008 ;
- La classe 5 représente les parcelles ayant toujours été en culture sur la période 1997-2008 (11 à 12 années en culture).

Trois classes de prairies ont aussi été définies :

- La classe 1 représente les parcelles dites prairies de longue durée ayant toujours été en prairie sur la période 1997-2008 (11 à 12 années en prairies) ;
- La classe 2 représente les parcelles en prairies consécutivement pendant 6 à 10 années, dites prairies permanentes ;
- La classe 3 représente les parcelles en prairies consécutivement pendant 1 à 5 années, dites prairies temporaires ou artificielles.

Le regroupement des successions culturales en cinq classes montre clairement une prédominance des surfaces en prairie sur le bassin versant du Yar sur la période 1997-2008 (Figure 1.22-a2). De plus, on observe que la superficie moyenne des parcelles varie selon le type de successions culturales. Ainsi, les parcelles toujours en prairie ont une superficie moyenne de 0.5ha alors que les parcelles toujours en culture ont une superficie moyenne de 2ha. La spatialisation des successions culturales, illustrée par la figure 1.22-a3, montre que les prairies caractérisées par de petites parcelles sont plus présentes au sud et au centre du bassin versant, en fonds de vallées. Les cultures sont, quant à elles, plus présentes au nord du bassin versant qui est caractérisé par un paysage plus ouvert et des parcelles plus grandes, en grande majorité exploitées par des céréaliers.

Enfin, le regroupement des prairies selon leur durée en trois classes montre une prédominance des prairies de type permanentes ou longue durée (STH) avec près de 30% des parcelles toujours en prairie et 30% recouvertes de 6 à 10 années consécutives, soit près de 60% de la surface totale en prairie. Ainsi, 40% des prairies sont considérées comme temporaires au cours de la période d'étude (Figure 1.22-b2). De plus, on observe que la superficie moyenne des parcelles de prairies dites permanentes est inférieure à celle des prairies dites temporaires,

de 0.6ha contre 1.2ha, respectivement. La spatialisation des types de prairie selon leur durée, illustrée par la figure 1.22-b3, montre que les prairies temporaires sont plus présentes dans le nord du bassin versant où elles sont intégrées dans les rotations culturales, alors que les prairies permanentes sont plus présentes dans la partie sud et centre du bassin versant, là où les exploitations sont davantage destinées à l'élevage bovin.

### 1.3.2.2.3. Les facteurs expliquant la dynamique spatio-temporelle des prairies

Les facteurs motivant l'implantation, le maintien ou le retournement des prairies et les échelles auxquelles s'expriment ces facteurs (parcelle, îlot parcellaire, exploitation agricole, bassin versant, Région, État, Union Européenne) ont été identifiés et hiérarchisés à la suite d'une rencontre réunissant des agriculteurs, des représentants de la Communauté de commune de la Lieue de Grève et de la Chambre d'Agriculture et des chercheurs (Tableau 1.4). Les facteurs qui expliquent l'évolution de la répartition des prairies observée depuis les années cinquante sur le bassin versant du Yar sont nombreux et sont soit externes soit internes à l'exploitation agricole. Il ressort que les facteurs externes à l'exploitation agricole pèsent lourdement sur l'orientation globale prise par l'agriculteur pour son exploitation (choix du système de production et place de l'herbe dans celui-ci) alors que les paramètres locaux telles que la localisation de la parcelle et l'environnement d'une ou d'un groupe de parcelles jouent plutôt sur l'attribution des rotations et successions culturales.

Tableau 1.4 – Facteurs expliquant la dynamique spatio-temporelle des prairies

<b>Facteurs externes à l'exploitation agricole</b>	- Les politiques globales (législations et subventions)
	- Les politiques locales (notamment environnementales)
	- Les perspectives de contractualisation
	- L'économie
	- Le climat
<hr/>	
	<i>A l'échelle globale</i>
	- Le niveau de production (niveau d'intensification)
	- Le système de production (ex : conventionnel <i>vs</i> bio)
	- Les quotas laitiers
	- Le facteur humain (compétences, motivations)
<b>Facteurs internes à l'exploitation agricole</b>	<i>A l'échelle de la parcelle ou d'un groupe de parcelles</i>
	- Proximité au siège d'exploitation
	- Accès
	- Taille
	- Proximité à un point d'eau
	- Proximité à la zone d'étude
	- Qualité des sols
	- Niveau de la pente
	- Exposition

### 1.3.2.3. La tendance des dernières années : de 2008 à 2011

Dans le contexte des programmes de lutte contre les algues vertes, les acteurs présents sur le bassin versant du Yar (agriculteurs, gestionnaires de bassin versant, ...) participent à l'élaboration de solutions pour diminuer les flux d'azote tout en maintenant des exploitations viables. Ainsi, à travers la mise en place de fermes pilotes depuis 2010, les acteurs ont cherché à adapter les pratiques agricoles réalisées sur les parcelles pour faire évoluer les systèmes vers des pratiques plus durables. L'objectif principal étant de maintenir voir d'augmenter la part de l'herbe sur le bassin versant. La cartographie de l'occupation des sols entre 2008 et 2011 à partir de données de télédétection montre une stabilité des couverts prairiaux au sein de la surface totale et de la SAU du bassin versant (Tableau 1.5).

Tableau 1.5 – Évolution des surfaces en culture et en prairie entre 2008 et 2011 sur le bassin versant du Yar

		2008	2009	2010	2011
Cultures	en <i>ha</i>	1470	1640	1538	1406
	en % de la ST	24	27	25	23
	en % de la SAU	40	43	40	38
Prairies	en <i>ha</i>	2320	2150	2252	2384
	en % de la ST	38	35	37	39
	en % de la SAU	60	57	60	62



## 1.4. Les données et leur traitement

---

### 1.4.1. Les données de télédétection

L'identification des prairies et des pratiques qui leur sont associées sur le bassin versant du Yar est effectuée à partir d'images de télédétection acquises par des capteurs optiques et radars à haute et très haute résolution spatiale. Ce choix s'explique, d'une part, par la taille des prairies de la zone d'étude (en moyenne inférieures à  $1ha$ ) et d'autre part, par une couverture nuageuse fréquente.

#### 1.4.1.1. Les images satellites optiques

##### 1.4.1.1.1. Description

Trois séries de 4 à 5 images optiques acquises en 2006, 2010 et 2011 ont été utilisées pour identifier et caractériser les prairies (Tableau 1.6). Ces images, qui ont des résolutions spatiales comprises entre 5 et 30  $m$ , apparaissent bien adaptées aux paysages agricoles dont la superficie moyenne des parcelles est inférieure à  $1ha$ . De plus, des études ont montré que les images de types SPOT, Landsat et Quickbird sont généralement bien adaptées pour les applications agricoles et le suivi de la végétation [Homolová *et al.* 2013, Xie *et al.* 2008, Grant *et al.* 2012, Claverie *et al.* 2012, Yang *et al.* 2011, El Hajj *et al.* 2009, Price *et al.* 2002]. De plus, les images des trois séries considérées présentent des dates d'acquisition différentes permettant ainsi d'évaluer l'intérêt de chacune en fonction des pratiques agricoles.

Ces séries ont été utilisées indépendamment les unes des autres pour évaluer leur apport respectif pour l'étude de l'évolution intra-annuelle des prairies et de leur mode de gestion. Les images SPOT ont été acquises dans le cadre de programmes ISIS (financier : CNES), l'image Landsat ayant été acquise dans le cadre du programme TOSCA (financier : CNES).

##### 1.4.1.1.2. Les pré-traitements

Dans un premier temps, les images ont été corrigées des effets radiométriques et atmosphériques qui perturbent le signal (effets liés au capteur et à l'atmosphère), ces corrections étant indispensables pour comparer des images satellites prises sur une même zone d'étude à des dates différentes (comparaison multi-dates, étude multi-temporelle). Ces corrections permettent de passer des valeurs brutes (comptes numériques) à des valeurs physiques de réflectance de surface [Kergomard 2000]. Pour ce faire, l'application du modèle 6S (Second Simulation of a Satellite Signal in the Solar Spectrum vector code), modèle de corrections atmosphériques développé au laboratoire d'optique atmosphérique de l'USTL [Vermote *et al.* 1997] et version améliorée du 5S [Tanré *et al.* 1990], permet de corriger les effets de diffusion et

Tableau 1.6 – Caractéristiques des images de télédétection optique utilisées

Date de prise de vue (DOY)	Capteur	Résolution spatiale ( <i>m</i> )	Bandes spectrales * ( $\mu\text{m}$ )
<b>2006</b>			
19/03/2006 (78)	Quickbird 5	2.5	V, R, PIR
06/04/2006 (96)	SPOT-2 HRV1	20	V, R, PIR
01/06/2006 (152)	SPOT-5 HRG2	10	V, R, PIR, MIR
18/07/2006 (199)	SPOT-5 HRG1	10	V, R, PIR, MIR
23/09/2006 (266)	SPOT-4 HRVIR2	20	V, R, PIR, MIR
<b>2010</b>			
19/04/2010 (109)	SPOT-5 HRG2	5	V, R, PIR
21/05/2010 (141)	SPOT-5 HRG1	10	V, R, PIR
26/06/2010 (177)	SPOT-5 HRG1	5	V, R, PIR
02/09/2010 (245)	LANDSAT TM	30	V, R, PIR, MIR
<b>2011</b>			
21/03/2011 (80)	SPOT-4 HRVIR2	20	V, R, PIR, MIR
22/04/2011 (112)	SPOT-4 HRVIR2	20	V, R, PIR, MIR
23/05/2011 (143)	SPOT-4 HRVIR2	20	V, R, PIR, MIR
10/08/2011 (222)	SPOT-4 HRVIR1	20	V, R, PIR, MIR
15/10/2011 (288)	SPOT-4 HRVIR2	20	V, R, PIR, MIR

\*V= Vert, R= Rouge, PIR= Proche InfraRouge et MIR= Moyen InfraRouge

d'absorption modifiant le signal. Le passage des valeurs numériques aux valeurs de réflectance comprend trois étapes : le passage des comptes numériques en luminance, puis des valeurs de luminance en réflectance éxo-atmosphérique et enfin des valeurs éxo-atmosphériques en réflectance au sol. Ces corrections ont été appliquées sur chacune des bandes des différentes images utilisées.

Dans un second temps, les images ont été corrigées géométriquement à partir de l'orthophotoplan IGN de 2008 (©IGN - Institut Géographique National), afin de pouvoir superposer les images les unes par rapport aux autres et ainsi éliminer les distorsions enregistrées par le capteur (altitude, rotation, courbure, ...). Le système de projection utilisé est le Lambert II étendu correspondant aux données parcellaires et à l'orthophotoplan disponibles sur le site d'étude.

### 1.4.1.1.3. Les traitements

#### 1.4.1.1.3.1. Calcul du NDVI

Une fois les images corrigées atmosphériquement, radiométriquement et géométriquement, l'indice de végétation par différence normalisée (NDVI - Normalized Difference Vegetation Index) a été calculé pour chacune des images utilisées. Cet indice est le plus connu et le plus utilisé pour suivre la végétation et est calculé à partir des bandes du rouge (R) et du proche-infrarouge (PIR) des images satellites [Rouse *et al.* 1974, Tucker 1979]. Le NDVI illustre la différence entre ces deux bandes :  $NDVI = (PIR-R)/(PIR+R)$ . Ainsi, il est sensible à la densité et à l'état de la végétation : quand l'activité chlorophyllienne augmente, la réflectance dans la bande du rouge diminue alors que la réflectance dans la bande du proche-infrarouge augmente. Plus la végétation sera dense, plus les valeurs de NDVI seront proches de 1.

#### 1.4.1.1.3.2. L'estimation des variables biophysiques : utilisation du modèle couplé PROSPECT+SAIL (PROSAIL)

Le modèle de transfert radiatif PROSAIL est appliqué afin d'obtenir des variables biophysiques à partir des séries temporelles d'images satellites. L'exploitation de ces variables, estimées à partir des séries temporelles d'images, permet de reconstituer l'évolution des surfaces en fonction de la croissance de la végétation et des pratiques agricoles mises en place [Jacquemoud *et al.* 2009].

### Principes

Le modèle PROSPECT simule la réflectance et la transmittance des feuilles à partir de la structure du couvert et des teneurs en chlorophylle, en eau et en matière sèche. Le modèle SAIL simule la réflectance du couvert en utilisant les sorties de PROSPECT, c'est-à-dire la réflectance du sol, les géométries d'illumination et d'observation de la scène et la structure du couvert (Figure 1.23-a).

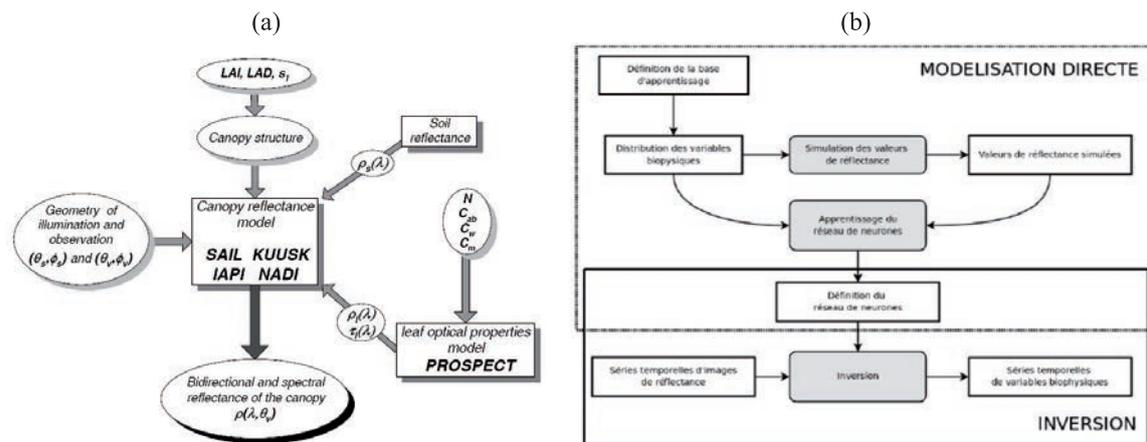


Figure 1.23 – Entrées et sorties des modèles PROSPECT et SAIL [Bacour & Jacquemoud 2001] (a) et Schéma conceptuel du modèle de transfert radiatif direct et inverse PROSPECT-SAIL (d'après [Bacour *et al.* 2003], in [Lecerf 2008]) (b)

La modélisation du transfert radiatif se déroule en deux étapes (Figure 1.23-b) : d'abord la modélisation directe des réflectances puis l'inversion de celles-ci pour obtenir les variables biophysiques [Lecerf 2008, Bacour *et al.* 2003]. Ainsi, en premier lieu, le modèle de transfert radiatif permet de simuler des valeurs de réflectance en fonction de paramètres biophysiques déterminés au préalable par l'utilisateur (modèle direct). En deuxième lieu, un réseau de neurones est utilisé pour réaliser l'inversion du modèle [Weiss *et al.* 2007, Bacour *et al.* 2006], la base d'apprentissage étant constituée des valeurs de réflectance précédemment simulées pour estimer les variables biophysiques (modèle indirect). La méthode par réseau de neurones permet de calculer la relation entre les réflectances et les paramètres du couvert (variables biophysiques) et ainsi d'estimer des variables de sorties à partir des variables d'entrée [Bacour *et al.* 2003]. Plus précisément, le réseau de neurones utilisé par le modèle couplé PROSPECT-SAIL pour estimer des variables biophysiques à partir de données de réflectance est « *un perceptron multicouche avec rétropropagation de gradient (deux couches : une avec des fonctions d'activations sigmoïdales et l'autre avec une fonction d'activation linéaire)* » [Bacour *et al.* 2006].

### Variables d'entrée et de sortie du modèle

Les modèles PROSPECT et SAIL utilisent plusieurs variables d'entrée (Figure 1.23-a). Concernant le modèle PROSPECT, cinq paramètres sont à définir : la teneur en chlorophylle des végétaux ( $C_{ab}$ ), la teneur en matière sèche ( $C_{dm}$ ), la teneur en eau ( $C_w$ ), la teneur en carotène ( $C_{ar}$ ) et le nombre de couches du modèle ( $N$ ). Pour le modèle SAIL, quatre paramètres sont à définir : la surface foliaire ( $LAI$ ), l'orientation moyenne des feuilles ( $ALA$ ,  $LIDFA$ ,  $LIDFB$ ), le HotSpot correspondant au rapport entre la taille moyenne des feuilles et la hauteur du couvert, et le facteur de brillance des sols ( $B_s$ ). La distribution des variables d'entrée nécessaires pour calibrer le modèle PROSAIL est présentée dans le tableau 1.7. Les variables décrivant la structure du couvert et les propriétés optiques des feuilles sont définies à partir de connaissances acquises sur les caractéristiques biologiques et chimiques des surfaces et utilisées pour le paramétrage du modèle appliqué sur les données à moyenne résolution spatiale CYCLOPES [Baret *et al.* 2007] et d'après la littérature déjà disponible sur le sujet [Lecerf *et al.* 2008, Weiss *et al.* 2000, Feret *et al.* 2008]. Plusieurs études ont déjà utilisées des distributions de variables d'entrée similaires pour appliquer PROSAIL à des données à haute résolution spatiale [Claverie *et al.* 2013, Duveiller *et al.* 2011, Bsaibes *et al.* 2009, Lecerf *et al.* 2008, Soudani *et al.* 2006]. En plus des paramètres décrivant le couvert végétal, plusieurs paramètres décrivant la géométrie de la scène sont à renseigner en entrée du modèle (Figure 1.23-a) : l'angle zénithal solaire (SZA), l'angle zénithal de visée (VZA), l'angle azimutal solaire (SAA) et l'angle azimutal de visée (VAA). Enfin, des signatures spectrales de sols nus acquises lors de campagne de terrain ont été intégrées dans le modèle pour prendre en compte l'influence des sols sur les réflectances (Figure 1.23-a).

L'application du modèle couplé PROSAIL permet d'estimer un ensemble de variables biophysiques. Dans le cadre de cette thèse seul le LAI et le fCOVER seront utilisés du fait de leur intérêt pour le suivi des couverts végétaux [Jacquemoud *et al.* 2009, Zhang & Guo 2008, Guo *et al.* 2000, Friedl *et al.* 1994, Asam *et al.* 2013, Chen & Black 1991, Darvishzadeh *et al.* 2008, Lecerf *et al.* 2008].

Tableau 1.7 – Caractéristiques des variables d’entrée utilisées pour calibrer le modèle PRO-SAIL

	Variables	Min	Mean	Max	Std	Law	class
Canopy	LAI	0	2	7	-	Uniform	6
	ALA (°)	30	60	80	20	Gaussian	4
	Hotspot	0.001	0.1	1	0.3	Gaussian	1
Leaf	$N$	1	1.5	2.5	1	Gaussian	4
	$C_{ab}$ ( $\mu\text{g cm}^{-2}$ )	20	50	90	30	Gaussian	4
	$C_{dm}$ ( $\text{g cm}^{-2}$ )	0.001	0.007	0.02	0.0045	Gaussian	4
	$C_w$	0.65	0.85	0.75	-	Uniform	4
	$C_{bp}$	0	2	0.03	0.2	Gaussian	4
Soil	$B_s$	0.1	1.5	2	0.5	Gaussian	4

### 1.4.1.2. Les images satellitales radars

#### 1.4.1.2.1. Description

Deux séries d’images Radarsat-2, acquises en 2010 et 2011, ont été évaluées pour identifier et caractériser les prairies (Tableau 1.8). Ce sont des images d’intensité enregistrées dans la bande C (5.405 GHz), déjà largement utilisée et relativement bien adaptée pour les applications agricoles [McNairn & Brisco 2004, Liu *et al.* 2013, Smith & Buckley 2011, Buckley & Smith 2010, Baghdadi *et al.* 2001, Freeman *et al.* 1994]. La série de 2010 a été acquise en mode polarimétrique, qui comprend les quatres polarisations HH, VV, VH et HV. La série de 2011 a été acquise en mode Ultra-Fin, qui présente l’avantage d’une résolution spatiale très fine, mais qui est limité à une seule polarisation, VV en l’occurrence.

Ces deux séries ont été utilisées indépendamment l’une de l’autre pour évaluer leur apport respectif pour l’étude de l’évolution intra-annuelle des prairies et de leur mode de gestion. Ces images RADARSAT-2 ont été acquises dans le cadre du projet VIGISAT (Financier : Région Bretagne et Union Européenne et fournisseur : CLS).

#### 1.4.1.2.2. Les prétraitements et l’extraction des paramètres radars

Toutes les images radars utilisées pour ce travail ont été fournies en Single Look Complex (SLC), format qui conserve les informations de phase et d’amplitude.

Dans un premier temps, une matrice de cohérence [T3] a été extraite des images Radarsat-2 « Fine Quad-polarisation » (acquises en 2010). Puis, les images ont été corrigées des effets de chatoiement (speckle) qui dégradent la lisibilité de l’image. Le chatoiement est du à la diffusion multiple qui se produit dans chaque pixel de l’image. Ainsi, la rétrodiffusion d’un milieu homogène apparaît comme un signal non constant, hétérogène et d’apparence bruitée. Il existe plusieurs filtres visant à corriger cet effet. Pour cette étude, le filtre de Lee [Lee *et al.* 1999] a été appliqué sur les images radars afin de réduire le bruit de l’image tout en préservant l’information spatiale et polarimétrique de l’image. Puis les images ont été corrigées géométriquement à partir d’un modèle numérique de terrain issu du Shuttle Radar Topogra-

Tableau 1.8 – Caractéristiques des images de télédétection radar utilisées

	2010	2011
<b>Spatial Resolution</b>	12*12m	2*2m
<b>Band</b>	C-Band	C-Band
<b>Polarization*</b>	HH, VV, HV, VH (Full)	VV (Single)
<b>Mode</b>	Fine Quad-Polarisation	Ultra Fine
<b>Incidence angle</b>	37.56° to 38.51°	37.56° to 46.04°
<b>Nominal look direction</b>	Right Ascending	Right Ascending
<b>Swath width</b>	25km*25km	20km*20km
<b>Dates (DOY)</b>	02/02/2010 (33) 15/06/2010 (166) 09/07/2010 (190)	27/05/2011 (147) 20/06/2011 (171) 01/08/2011 (219)
(Days Of the Year)	02/08/2010 (214) 26/08/2010 (238)	31/08/2011 (243)

\*HH= Horizontal/Horizontal, VV= Vertical/Vertical, HV= Horizontal/Vertical et VH= Vertical/Horizontal

phy Mission (SRTM), du parcellaire disponible sur le site d'étude et d'un orthophotoplan. Enfin, les coefficients de rétrodiffusion (HH, VV, VH, HV) en  $\sigma^0$  (dB) et les ratios d'intensité (HH/VV, HH/VH et VV/VH) ont été calculés d'après la matrice de cohérence [T3] avant d'appliquer deux modèles de décomposition polarimétrique : Freeman–Durden [Freeman & Durden 1998] et Cloude–Pottier [Cloude & Pottier 1997].

Les images Radarsat-2, acquises en mode « Ultra-Fin » ont d'abord été filtrées pour réduire le bruit présent, puis chaque image d'intensité a été transformée en coefficient de rétrodiffusion ( $\sigma^0$  en dB). Enfin, ces images ont été corrigées géométriquement.

### 1.4.1.3. Structuration des paramètres issus des données de télédétection du pixel à la parcelle

L'ensemble des variables et paramètres dérivés des données optiques et radars ont été intégrés dans un SIG : les données « raster » ont été transformées en données « vecteur » en utilisant une couche de limites parcellaires numérisée à partir de l'orthophotoplan. En effet, alors que les images satellites optiques et radars utilisées dans le cadre de cette thèse ont des résolutions spatiales différentes, les variables et paramètres qui ont été dérivés des images à l'échelle pixellaire ont dû être transformés à l'échelle parcellaire. La valeur moyenne des pixels inclus dans une parcelle a été affectée à l'ensemble de la parcelle (Figure 1.24-a). Ainsi, chaque variable ou paramètre dérivé des images satellites est représenté par une valeur unique par parcelle à chaque date d'acquisition soit :  $\chi(i, l, t)$  avec  $i$  les  $n$  parcelles du site d'étude,  $l$  les  $m$  variables et paramètres dérivés des images satellites et  $t$  les dates d'acquisition des images satellites (Figure 1.24-b).

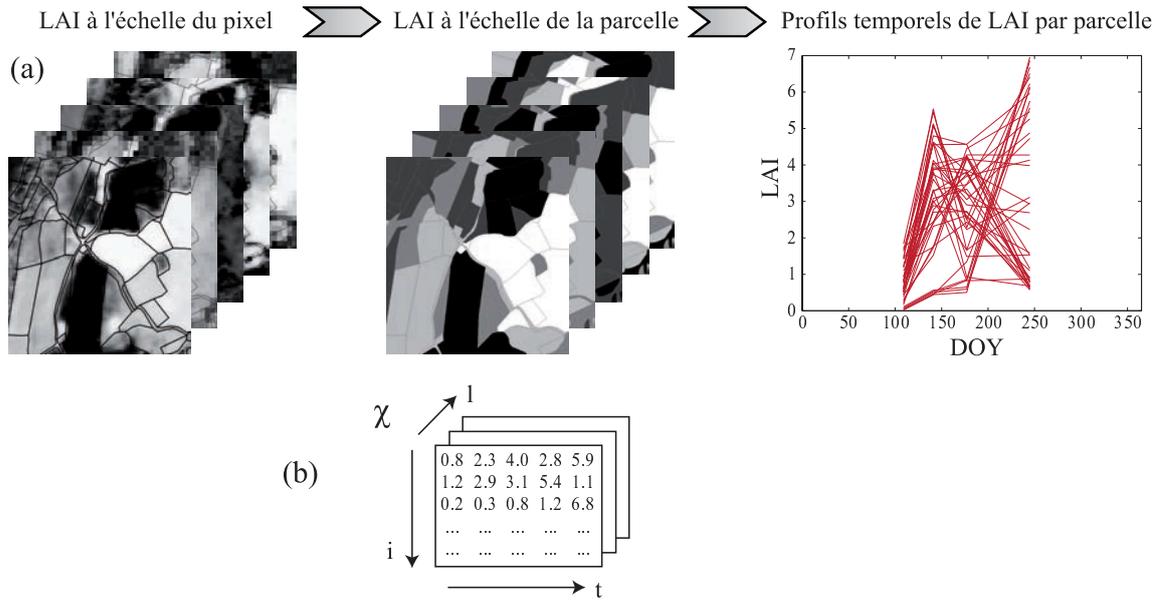


Figure 1.24 – Transformation des paramètres dérivés des données de télédétection de l'échelle du pixel à la parcelle. Exemple sur un extrait de la zone d'étude représentant la variable LAI (a) et la base de données (b)

#### 1.4.1.4. Classification des données

##### 1.4.1.4.1. Les méthodes utilisées

Deux méthodes de classification supervisées ont été testées : la méthode des  $k$  plus proches voisins (KNN - K-Nearest Neighbor) et la méthode des séparateurs à vastes marges (SVM - Support Vector Machine). Ce choix s'explique par le fait que ces méthodes, qui présentent des caractéristiques bien différentes, ont été largement exploitées pour tous les types d'images de télédétection, qu'elles soient optiques, radars, mono-bandes ou multi-bandes [Schuster *et al.* 2015, Hao *et al.* 2014, Mountrakis *et al.* 2011, Nait Chabane & Belhadj-Aissa 2009, McRoberts & Tomppo 2007, Gjertsen 2007, Huang *et al.* 2002].

Nous supposons qu'un *ensemble d'apprentissage*  $\mathcal{V} = \{(\mathbf{t}_1, \mathbf{y}_1), \dots, (\mathbf{t}_N, \mathbf{y}_N)\}$  est disponible, contenant  $N$  échantillons de la série temporelle  $\mathbf{t}_i = [t_{i,1}, t_{i,2}, \dots, t_{i,n}]^T$  de taille  $n$  avec les libellés de classe correspondants  $\mathbf{y}_i$ . Cet ensemble d'apprentissage a été constitué à partir d'observations terrain (détails dans la section 1.4.2, page 56).

##### 1.4.1.4.1.1. La méthode des $k$ plus proches voisins - KNN

La méthode des  $k$  plus proches voisins (KNN) [Cover & Hart 1967a] est une des méthodes de classification les plus simples. La distance entre le pixel à classer et les pixels échantillons est calculée à partir de l'ensemble d'apprentissage (Figure 1.25). Les  $k$  plus proches échantillons de l'ensemble d'apprentissage ( $k$  étant à fixer par l'utilisateur) sont ainsi extraits d'après

cette distance. Le pixel à classer sera affecté à la classe majoritaire parmi les  $k$ . La mesure de distance est à fixer par l'utilisateur, la plus simple et la plus utilisée étant la distance euclidienne (norme  $L_2$ ).

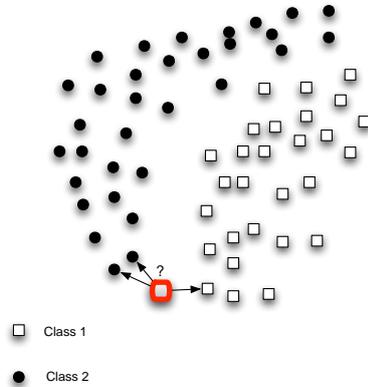


Figure 1.25 – Illustration de la méthode de classification KNN. Pour une nouvelle entrée donnée, les  $k$  plus proches voisins (ici  $k=3$ ) sont extraits et le label majoritaire parmi ces entités est associé à la nouvelle entrée (rond noir dans cet exemple)

#### 1.4.1.4.1.2. La méthode des séparateurs à vastes marges - SVM

La méthode des séparateurs à vastes marges (SVM) a été initialement conçue pour des classifications de type binaire [Cortes & Vapnik 1995].

Les SVM ont pour principe de chercher un séparateur optimal pour les différentes classes de l'ensemble d'apprentissage [Vapnik 1995] (frontière de séparation qui maximise la distance entre cette dernière et les échantillons les plus proches) (Figure 1.26). Si la séparation entre les données d'entrée  $\mathbf{t}_i$  est non linéaire, une technique efficace consiste à transformer l'espace de représentation des données d'entrée ( $\phi(\mathbf{t}_i)$ ) en un espace de plus grande dimension dans lequel il est possible de trouver un hyperplan séparateur linéaire. Afin d'éviter des calculs dans des espaces de trop grande dimension, on ne s'appuie en général que sur le *noyau* (kernel) qui fournit l'expression du produit scalaire dans cet espace de grande dimension. Les données d'entrée sont comparées avec des fonctions noyau et la meilleure séparation linéaire entre les classes, qui correspond au plus grand écart entre deux classes, est utilisée comme hyperplan séparateur. Ainsi, les objets à classer sont comparés dans l'espace transformé et un label leur sera attribué en fonction de leur position par rapport à la frontière de séparation (hyperplan séparateur linéaire). Ce principe a été étendu à la classification multi-labels [Zhang 2001]. En pratique le noyau le plus utilisé est le noyau Gaussien car il correspond à la transformation dans un espace de dimension infinie (et donc optimal) :

$$\langle \phi(\mathbf{t}_1), \phi(\mathbf{t}_2) \rangle = \exp(-\gamma \|\mathbf{t}_1 - \mathbf{t}_2\|^2), \quad (1.1)$$

où  $\gamma$  est un paramètre à définir.

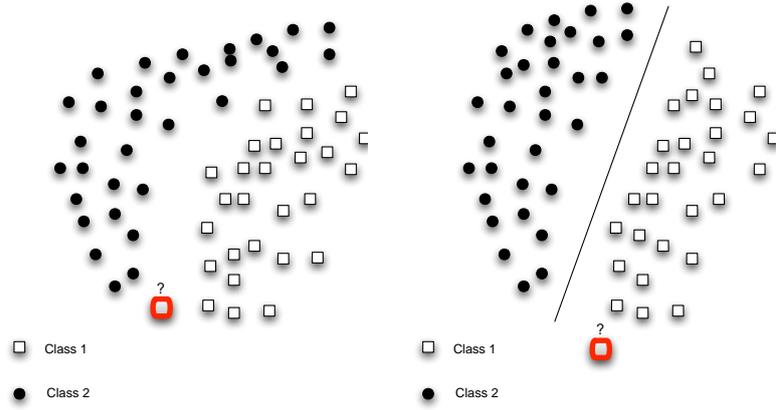


Figure 1.26 – Illustration de la méthode de classification SVM. A partir d'un ensemble d'apprentissage où la séparation entre classes est non linéaire (gauche), on le transforme afin d'obtenir une séparation linéaire (droite). Un nouveau point sera affecté à une classe en fonction de sa position par rapport à la frontière

#### 1.4.1.4.2. La validation des classifications

Deux indices permettant d'évaluer la performance des classifications ont été calculés : la précision globale (OA : Overall Accuracy) et l'indice de Kappa ( $K$ ) [Congalton 1991, Cohen 1960] :

$$K = \frac{P_g - P_m}{1 - P_m} \quad (1.2)$$

où  $P_g$  représente la précision globale (le taux global de bonne classification) :  $P_g = \frac{\sum_{i=1}^C M_{ii}}{N}$  avec  $M_{ii}$  le nombre d'échantillons de la classe  $i$  correctement classés,  $N$  le nombre total d'échantillons et  $C$  le nombre de classes.

$P_m = \left( \frac{\sum_{i=1}^C T1(i)T2(i)}{N^2} \right)$  est le rapport des échantillons marginaux et est calculé en utilisant  $T1(i) = \sum_{k=1}^C M_{ik}$  avec  $M_{ik}$  le nombre d'échantillons de la classe  $i$  affectés à la classe  $k$  et  $T2(i) = \sum_{k=1}^C M_{ki}$  avec  $M_{ki}$  le nombre d'échantillons de la classe  $k$  affectés à la classe  $i$ .

Ainsi, l'indice de Kappa prend en compte les erreurs de sous-estimation (omission) et de sur-estimation (commission). Ces erreurs, calculées à partir de la matrice de confusion (tableau à double entrée représentant en ligne les résultats de la classification et en colonne les résultats par rapport aux données de référence), permettent d'analyser la précision de la classification. Généralement, il a été établi que des classifications avec des valeurs de  $K$  supérieures à 0.8 sont excellentes, des classifications avec des valeurs de  $K$  comprises entre 0.6 et 0.8 sont acceptables et des classifications avec des valeurs de  $K$  comprises entre 0.4 et 0.6 montrent une précision faible.

## 1.4.2. Les observations et mesures terrain

Les campagnes de terrain ont été réalisées sur une dizaine de « fermes pilotes » réparties sur l'ensemble du bassin versant. Elles ont été sélectionnées de façon à représenter la diversité des espèces cultivées et des modes de gestion mis en place sur le site. Des parcelles ont été sélectionnées au sein de ces fermes afin de calibrer et de valider les traitements effectués sur les images satellites. Les prairies représentent 75% de l'échantillonnage et les cultures les 25% restant.

Plusieurs types d'informations ont été collectées mensuellement sur le terrain en 2006 et de 2010 à 2013 : des relevés d'occupation et d'utilisation des sols sur une centaine de parcelles ; des mesures spectrales et des photographies hémisphériques sur une vingtaine de parcelles ; des enquêtes auprès de quatre agriculteurs–exploitants. Enfin, des mesures de biomasse ont été réalisées sur huit parcelles par le comité de bassins versants de la Lieue de Grève en partenariat avec l'INRA - UMR Sol Agro–hydrosystèmes Spatialisation, Rennes et Quimper.

### 1.4.2.1. Les relevés d'occupation et d'utilisation des sols

Les relevés d'occupation et d'utilisation des sols regroupent plusieurs types d'information recueillis mensuellement sur les parcelles sélectionnées (Figure 1.27-a) :

- Une photographie en perspective de l'ensemble de la parcelle ;
- Une photographie verticale représentative de l'occupation du sol sur la parcelle ;
- Le type d'occupation du sol ;
- Le stade phénologique ;
- La pratique agricole ;
- L'état de surface ;
- Le taux de couverture moyen du sol par la végétation, relevé à l'aide de quadrats ;
- La hauteur moyenne de la végétation.

### 1.4.2.2. Les mesures spectrales

#### 1.4.2.2.1. Description

Les mesures spectrales ont été réalisées avec un spectro–radiomètre Analytical Spectral Devices (ASD) Fieldspec3 (Figure 1.28). Il s'agit d'un spectro–radiomètre portatif permettant de réaliser des mesures de réflectance *in situ* en spectres continus (résolution spectrale de 1nm) du visible au moyen infrarouge (350-2500nm) avec un angle d'ouverture de 25° [ASD 2000]. Les spectres ont été collectés le long d'un transect réalisé sur toute la longueur des parcelles enquêtées afin de représenter l'hétérogénéité intra–parcellaire du couvert [Boschetti *et al.* 2007]. Dix mesures de réflectance prises à environ 1.5m au-dessus du sol ont été collectées par parcelle, chacune de ces réflectances étant une moyenne de 50 mesures (Figure 1.27-b). Enfin, une cible de calibration (spectralon) (Figure 1.28-gauche) a été utilisée entre chaque mesure pour tenir compte des modifications de conditions atmosphériques et d'illu-

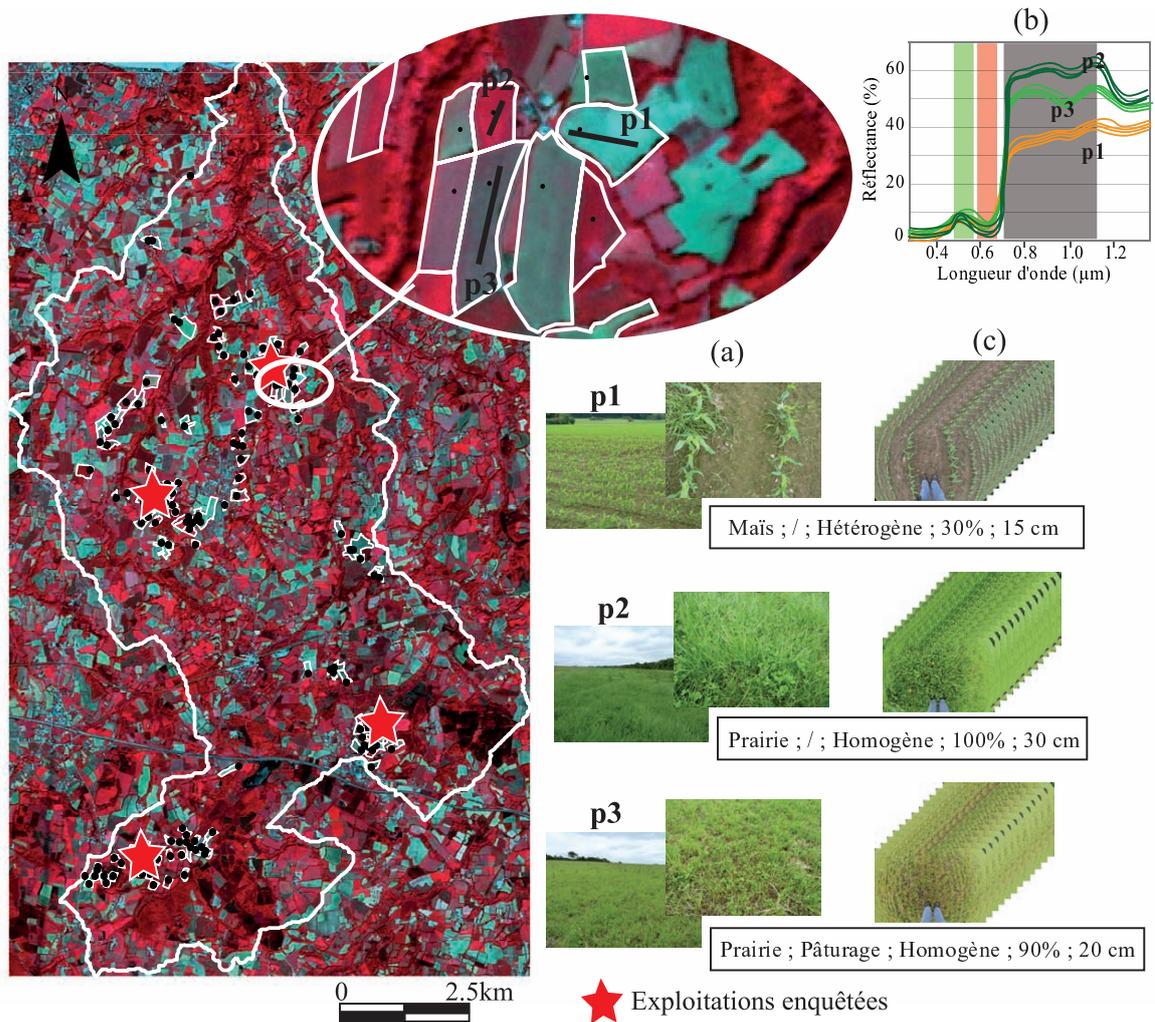


Figure 1.27 – Localisation des parcelles échantillonnées. Illustration de relevés d'occupation et d'utilisation des sols (a), mesures spectrales (b) et photographies hémisphériques (c)

mination entre deux mesures et supprimer ainsi les effets dus à l'éclairage solaire [Lillesand & Kiefer 2000]. Les mesures ont été réalisées chaque mois pendant la période de croissance de la végétation de mars à octobre.

#### 1.4.2.2.2. Pré-traitements

Les pré-traitements ont été effectuées en plusieurs étapes successives :

1- Les valeurs comprises entre 1350-1450nm, 1800-2070nm et 2350-2500nm ont été exclues (Figure 1.29-a et b) car les mesures spectrales, qui sont collectées en continu du domaine du visible au proche infrarouge, présentent des réflectances très bruitées dans les longueurs d'onde d'absorption de l'eau.

2- Seules les informations comprises dans les longueurs d'onde du visible et du proche infrarouge ont été conservées (ligne pointillée - Figure 1.29-b) dans le but de comparer les



Figure 1.28 – Calibration du spectro-radiomètre (à gauche) et collecte de profils spectraux (à droite)

mesures de réflectance *in situ* aux données de télédétection.

3- Les dix mesures spectrales acquises par parcelle ont été moyennées pour obtenir une signature spectrale unique pour chaque parcelle (Figure 1.29-c).

4- Les mesures spectrales ont été lissées en appliquant une moyenne mobile simple (Figure 1.29-d) afin d'éliminer les artefacts. La moyenne mobile est calculée par sous-groupe de  $n$  valeurs consécutives « glissantes », ici  $n = 20$ , le sous-groupe de valeurs utilisé pour calculer chaque moyenne se décalant de un en un sur l'ensemble des données.

5- Les mesures de réflectance *in situ* ont été ré-échantillonnées de  $1nm$  (résolution spectrale du spectro-radiomètre) à environ  $100nm$  (résolution spectrale des images satellites) afin de comparer les mesures spectrales *in situ* et les réflectances des images de télédétection (Figure 1.29-e).

6- Un indice de végétation, le NDVI [Rouse *et al.* 1974], très largement utilisé pour le suivi de la végétation [Fontana *et al.* 2008, Wang *et al.* 2005], a été calculé à partir de chaque mesure de réflectance *in situ*.

### 1.4.2.3. Les photographies hémisphériques

Différentes méthodes existent pour estimer des indices de surfaces foliaires [Jonckheere *et al.* 2004]. On peut distinguer les méthodes de mesures directes des méthodes de mesures indirectes. Les premières consistent en la collecte de feuilles (recueil de litière ou collecte sur pieds) alors que les deuxièmes sont basées sur la mesure de la fraction de trou *in situ*. La fraction de trou (ou transmittance) est fortement liée à la structure du couvert végétal et contribue au bilan radiatif des couverts végétaux. Ainsi, elle représente la probabilité qu'un rayon lumineux incident atteigne le sol sans être intercepté par les feuilles (sur un couvert végétal dense, la probabilité sera faible alors que sur un couvert végétal peu développé, la probabilité sera forte). Les méthodes directes nécessitent la collecte d'un grand nombre d'échantillons et demandent beaucoup de temps et de main d'œuvre. Ainsi, ces méthodes ne sont pas appropriées pour le suivi temporel des prairies à l'échelle d'un bassin versant.

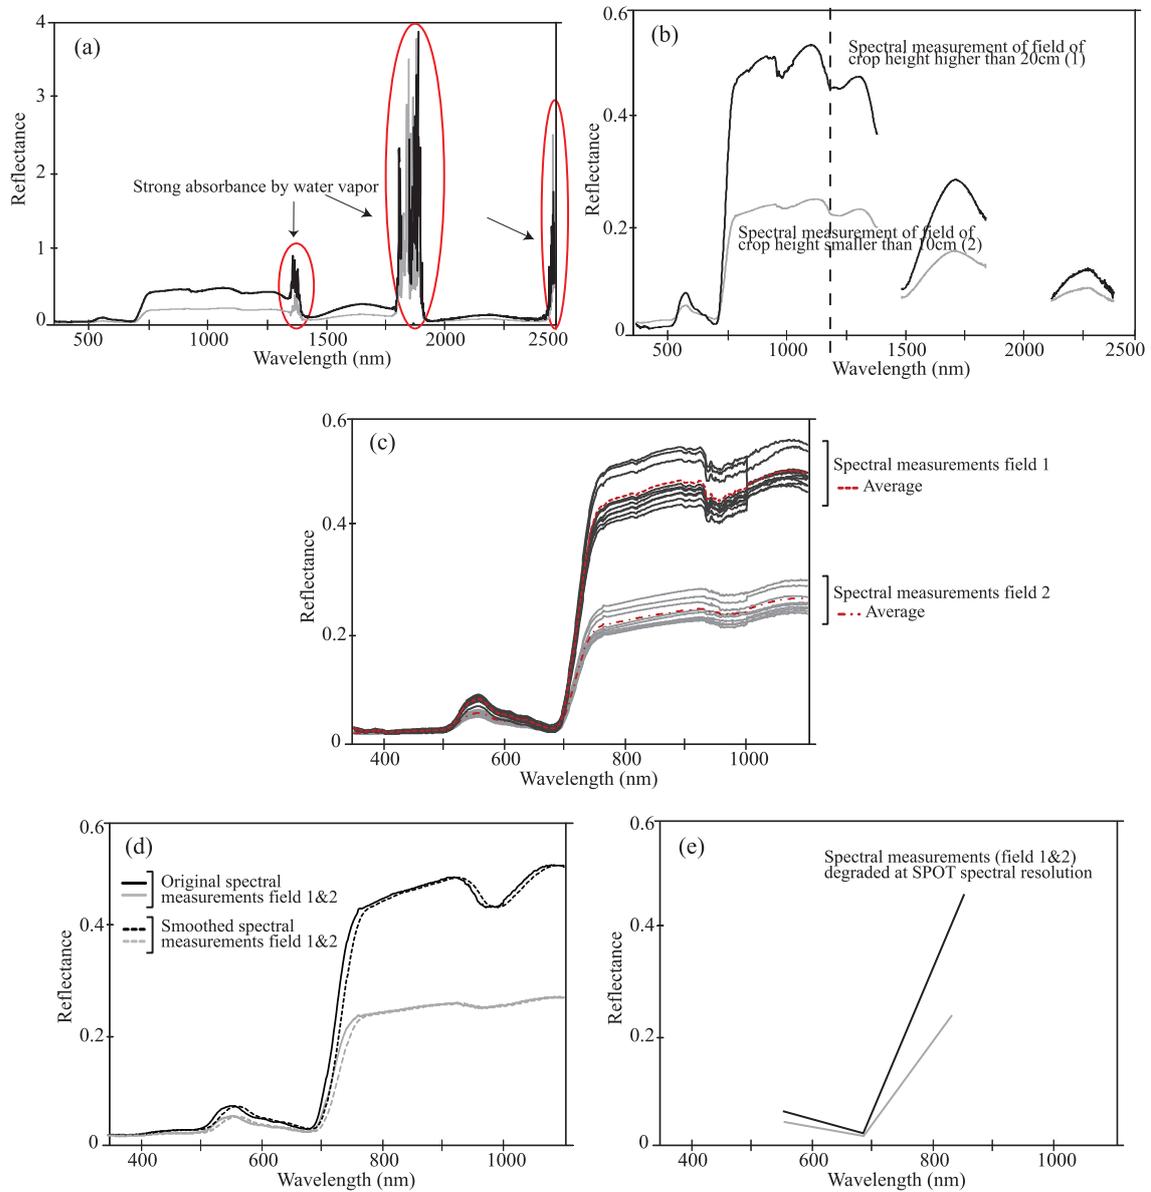


Figure 1.29 – Étapes de traitement des mesures spectrales collectées *in situ*. Exemple sur deux mesures de réflectance correspondant à une prairie ayant une hauteur de végétation supérieure à 20cm et une prairie ayant une hauteur de végétation inférieure à 10cm : exclusion des valeurs situées dans les longueurs d’onde d’absorption de l’eau (a et b), calcul des moyennes des mesures spectrales par parcelle (c), lissage des mesures spectrales (d) et ré-échantillonnage des réflectances *in situ* à la résolution des images satellites SPOT (e)

Cependant, ces méthodes servent à calibrer et valider les mesures obtenues à partir des méthodes indirectes [Baret *et al.* 2010, Weiss *et al.* 2004]. Ces dernières, qui relient la fraction de trou à la structure du couvert, sont plus facilement réalisables et moins coûteuses que les précédentes et elles permettent de constituer un échantillonnage plus important et plus étendu spatialement. Plusieurs modèles et techniques ont été développés pour mesurer la fraction de trou [Weiss *et al.* 2004, Nilson 1971] : le modèle de Poisson étant le modèle le plus simple et le plus utilisé. Il repose sur l'hypothèse d'une distribution aléatoire et uniforme des feuilles dans le couvert. Dans le cadre de cette thèse, la fraction de trou est estimée à partir du traitement de photographies hémisphériques, méthode très utilisée pour l'étude des couverts végétaux [Claverie *et al.* 2012, Baret *et al.* 2010, Demarez *et al.* 2008, Garrigues *et al.* 2008].

#### 1.4.2.3.1. Description

Les photographies hémisphériques ont été acquises avec un appareil photo Nikon D300S doté d'un objectif Nikon 10,5 mm f/2.8G ED AF DX Fisheye Nikkor ayant un angle de champ très grand (180°). Les photographies hémisphériques ont été acquises en « downward looking », c'est à dire en positionnant l'appareil photo à environ 1m au-dessus de la végétation (position en regardant vers le bas = le sol). Un minimum de 12 photographies a été pris pour chaque parcelle échantillonnée (Figure 1.27-c) afin de prendre en compte l'hétérogénéité intra-parcellaire [Weiss *et al.* 2004] pour estimer le LAI et le fCOVER.

#### 1.4.2.3.2. Pré-traitements

Le logiciel CAN-EYE V6.1 (© EMMAH - INRA Avignon) a été utilisé pour réaliser le traitement des photographies hémisphériques afin d'estimer le LAI et le fCOVER [Weiss & Baret 2010].

La première étape consiste à renseigner les paramètres de calibration et les options de traitements choisies : la valeur de l'angle zénithal maximum souhaité pour le calcul de la fraction de trou, les coordonnées du centre optique, le diamètre de l'image en pixels, le nombre de classes, etc. (Figure 1.30). Pour plus de détails sur la définition des différents paramètres et options de traitement se référer à [Demarez *et al.* 2008, Jonckheere *et al.* 2004, Weiss *et al.* 2004, Weiss & Baret 2010].

La deuxième étape consiste à supprimer les images inexploitable (floues, objectif non horizontal, ...) puis à masquer sur les images restantes les parties indésirables ou source d'erreurs pour la classification (pieds de l'utilisateur, artefacts, ...) (Figure 1.30-a).

Ensuite, les images sélectionnées et masquées sont classées automatiquement en deux catégories : végétation et sol. Cette classification automatique est ensuite affinée manuellement (Figure 1.30-b).

Enfin, la fraction de trou est calculée à partir des images classées pour fournir une estimation du LAI et du fCOVER [Garrigues *et al.* 2008, Demarez *et al.* 2008, Weiss *et al.* 2004].

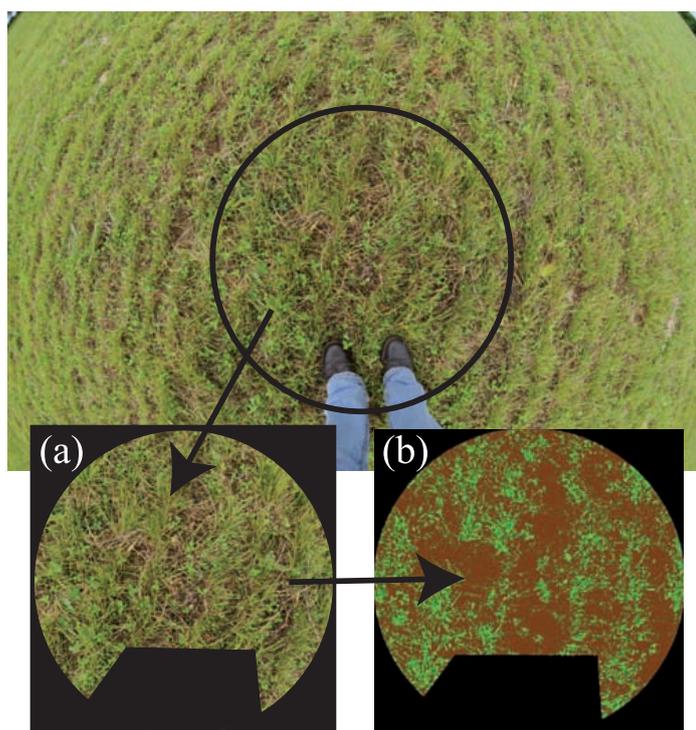


Figure 1.30 – Étapes de traitement des photographies hémisphériques prises dans les parcelles (illustrations d'une photographie prise sur une parcelle de culture caractérisée par une hauteur de moins de 10cm avec du sol visible : étape de masquage (a) et de classification (b))

#### 1.4.2.4. Les enquêtes

Des enquêtes ont été réalisées auprès de quatre agriculteurs-exploitants depuis 2010 afin de compléter les connaissances acquises sur le site d'étude notamment connaître la fréquence des pratiques agricoles effectuées sur les parcelles de prairie (Figure 1.27). Ainsi, ces enquêtes permettent d'évaluer la diversité des pratiques agricoles réalisées sur les prairies du bassin versant et leur fréquence au cours d'une année et leur variation d'une année sur l'autre.

#### 1.4.2.5. Les relevés de biomasse

Les exploitants de huit fermes pilotes en système de production laitier ont accepté de participer, dans le cadre du programme de recherche ANR ACASSYA, à la mise en place de modifications de leur système d'exploitation afin de réduire les pertes d'azote. Ces exploitants ont recensé dans un calendrier agricole les pratiques qu'ils effectuent sur leurs prairies (dates de pâturage et de fauche, durée et chargement animal pour chaque parcelle et fertilisation). De plus, certaines parcelles ont été sélectionnées pour des mesures directes de croissance de l'herbe (biomasse) afin d'analyser la variabilité intra-annuelle de la croissance de l'herbe en fonction des conditions climatiques. Ces parcelles présentent une grande diversité de situations : sol humide/sec, composition de graminées pures ou mélanges de graminées

et de légumineuses. Au total, une dizaine de parcelles de prairie ont été échantillonnées. Dans chacune de ces prairies, une zone grillagée de  $2m^2$  environ a été exclue du pâturage pour permettre la mesure de la biomasse. Chaque mois pendant la saison végétative, au sein de la zone en défens, l'herbe contenue dans quatre quadrats de  $70*70cm$  a été coupée à  $5cm$  de hauteur pour être pesée, séchée puis analysée pour mesurer la quantité de biomasse et les teneurs en eau et en azote. Dans ces même quadrats, des mesures de hauteur d'herbe avant et après le prélèvement d'herbe ont été réalisées. Le nombre de mesures par zone de prairies échantillonnées varie entre 5 et 8 selon les parcelles. Un total de 37 échantillons ont été recueillis sur le terrain.

Ces mesures ont été réalisées par Paul Salaun du comité des bassins versants de la Lieue de Grève.

## Synthèse et conclusion du premier chapitre

---

---

Le suivi des prairies en région agricole apparaît aujourd'hui comme un enjeu important tant sur le plan économique qu'environnemental. Les identifier et les caractériser pourrait permettre de mesurer l'impact des pratiques agricoles sur l'environnement et d'améliorer ces dernières afin de mettre en place de nouveaux systèmes agricoles cohérents dans le contexte d'une agriculture durable.

Les données disponibles pour cartographier la végétation sont nombreuses mais présentent des limites pour inventorier les prairies sur de larges secteurs et d'en assurer le suivi, ce qui explique le recours aux données de télédétection.

Globalement, la grande majorité des recherches centrées sur l'étude des prairies par télédétection vise à discriminer les prairies des autres couverts végétaux. Le plus souvent, cette discrimination est effectuée en utilisant des séries temporelles d'images provenant de capteurs à moyenne résolution spatiale qui offrent l'avantage de couvrir de larges superficies avec une forte répétitivité. Toutefois, ces données ont une résolution spatiale trop faible pour être utilisées dans des paysages agricoles fragmentés. D'autres études ont montré qu'il est possible d'identifier des prairies et d'observer leur évolution inter-annuelle en exploitant une à trois images à haute résolution spatiale acquises au cours d'une même année. Toutefois, la répétitivité limitée de ces données couplée à la fréquence de la couverture nuageuse constitue une limite forte pour discriminer les prairies des autres couverts végétaux et a fortiori les pratiques agricoles qui y sont effectuées. Ainsi jusqu'à présent, la faible précision spatiale des images à forte répétitivité temporelle et la faible répétitivité intra-annuelle des images à haute résolution spatiale ne permettaient pas d'identifier correctement les prairies et encore moins leurs modes de gestion.

Dans le contexte de la préparation des futures missions spatiales d'observation de la Terre *Venµs* et Sentinel et de la multiplication des satellites à haute résolution spatiale optiques et radars, des séries temporelles intra-annuelles d'images à haute résolution spatiale peuvent être élaborées afin d'évaluer leur potentiel pour identifier et caractériser les prairies.

Nous avons donc construit plusieurs séries temporelles intra-annuelles à partir d'images acquises par différents capteurs de type SPOT, Landsat et Radarsat-2 sur un site expérimental sur lequel nous avons effectué des mesures sur les prairies. Nous avons prétraité et traité ces séries afin de produire des paramètres (indices de végétation, variables biophysiques, paramètres radars tels que les décompositions polarimétriques, ou les intensités).

L'évaluation de ces paramètres et l'exploitation des plus pertinents d'entre eux pour le suivi des prairies sont présentées dans les chapitres suivants.

Les recherches présentées dans ce chapitre ont fait l'objet de plusieurs valorisations :

1- L. Delaby, F. Vertès, L. Ruiz, S. Devienne, S. Corgne, L. Hubert-Moy, **P. Dusseux**, J. Nabucet, 2015. *Des scénarios co-construits pour une transition agroécologique des systèmes d'élevage*, in Réconcilier Agriculture et Littoral. Cycle de l'azote, transition agroécologique d'un territoire, C. Gascuel-Odoux, F. Vertès, L. Ruiz coord., QUAE.

2- P. Durand, P. Moreau, L. Ruiz, J. Salmon-Monviola, F. Vertes, L. Hubert-Moy, S. Corgne, P. Faverdin, C. Baratte, E. Ramat, **P. Dusseux**, C. Benhamou, V. Parnaudeau, V. Viaud, T. Bouadi, M-O. Cordier, T. Rimbault, C. Gascuel, 2015. *Des modèles et des outils pour contribuer à des projets territoire*, in Réconcilier Agriculture et Littoral. Cycle de l'azote, transition agroécologique d'un territoire, C. Gascuel-Odoux, F. Vertès, L. Ruiz coord., QUAE.

3- S. Corgne, L. Hubert-Moy, R. Lecerf, A. Thomas, **P. Dusseux**, O. Planchon, 2012. *Changements d'occupation et d'utilisation des sols suivis par télédétection*, in Changement climatique dans l'Ouest, Évaluation, impacts, perceptions, P. Mérot, V. Dubreuil, D. Delahaye, P. Desnos coord., PUR, pp. 293-307.

# 2

Du terrain à l'image : Quels paramètres dérivés des séries temporelles d'images de télédétection optiques sont les plus adaptés à l'étude des prairies ?

## Sommaire

---

<b>Introduction . . . . .</b>	<b>67</b>
<b>2.1 Évaluation de paramètres dérivés d'une série temporelle optique à haute résolution spatiale pour estimer la biomasse des prairies . . .</b>	<b>69</b>
<b>2.2 Évaluation de paramètres dérivés d'une série temporelle optique à haute résolution spatiale pour discriminer des pratiques agricoles sur des prairies . . . . .</b>	<b>77</b>
<b>Synthèse et conclusion du second chapitre . . . . .</b>	<b>95</b>

---



## Introduction

---

Les prairies jouent un rôle très important tant sur le plan économique, pour la production de biomasse et de protéines pour les herbivores, que sur le plan environnemental pour la préservation de la qualité de l'eau, de l'air et des sols et de la biodiversité par la régulation des flux d'azote et de polluants et le stockage de carbone [White *et al.* 2000, Soussana & Lüscher 2007, Vertès *et al.* 2007]. Ainsi, dans les zones sensibles dominées par la production laitière, l'augmentation des surfaces en prairies pour l'élevage bovin associée à une utilisation raisonnée des couverts prairiaux participerait à la préservation de l'environnement [Moreau *et al.* 2012].

Or, pour passer à un système de production principalement basé sur l'herbe, en dehors des problèmes liés à la structure des exploitations agricoles et à l'accessibilité des prairies pour les animaux, les agriculteurs manquent d'informations sur la disponibilité de l'herbe sur l'ensemble de leur exploitation durant la saison végétative. En effet, les parcelles étant nombreuses et l'herbe étant principalement utilisée pour le pâturage dans les zones de production laitière, il est très difficile d'effectuer un suivi détaillé des pratiques agricoles et de la biomasse disponible au cours du temps. De plus, en raison du changement climatique qui se traduit par une hausse des températures et la modification du régime des précipitations, la productivité des prairies peut diminuer et conduire à un manque de fourrage pour les animaux, résultant en une perte économique et une insécurité alimentaire [Ruget 2013, Soussana 2013].

Par ailleurs, la connaissance des pratiques agricoles effectuées sur les prairies est très partielle : des relevés sont effectués sur les parcelles très ponctuellement dans le temps et dans l'espace, sans que l'on puisse les utiliser pour réaliser des inventaires exhaustifs et des suivis réguliers.

Pour connaître précisément la quantité d'herbe disponible dans les exploitations agricoles et les dynamiques spatio-temporelles des prairies et des pratiques agricoles effectuées sur celles-ci à des échelles territoriales, il est nécessaire d'avoir recours à des données acquises par télédétection [Price *et al.* 2002, Guo *et al.* 2000]. En effet, les données de télédétection offrent des perspectives intéressantes d'une part pour le suivi de la biomasse et d'autre part à identifier les modes de gestion pratiqués sur les prairies, et ceci à différentes échelles.

Dans les paysages agricoles fragmentés, caractérisés par une taille moyenne de parcelles réduite (moins de 1ha), l'utilisation de séries temporelles d'images satellites à haute résolution spatiale est nécessaire. Ainsi, les images SPOT, qui ont une résolution spatiale de 5m à 20m et une fréquence de revisite croissante avec la programmation d'images, peuvent être utilisées pour élaborer des séries temporelles intra-annuelle afin d'estimer la biomasse des

---

prairies et de les caractériser en déterminant leur modes de gestion.

Les paramètres dérivés des données de télédétection tels que les indices de végétation et les variables biophysiques sont adaptés à l'étude des couverts prairiaux [Hill 2013, He *et al.* 2009, Zhang & Guo 2008, Inoue & Oliosio 2006, Guo *et al.* 2000]. Parmi les indices de végétation, l'indice de végétation normalisé (NDVI) est le plus couramment utilisé pour décrire l'état de la végétation et la biomasse associée [Brüser *et al.* 2014, Lu 2006, Wang *et al.* 2005]. En termes de variables biophysiques, l'indice de surface foliaire (LAI) et la fraction de couverture végétale verte (fCOVER) sont largement utilisés car ils sont liés à la hauteur de la végétation, l'état de surface et la biomasse [Claverie *et al.* 2013, Asam *et al.* 2013, Jacquemoud *et al.* 2009, Bsaibes *et al.* 2009, Friedl *et al.* 1994, Wei 2010]. Cependant, il est encore nécessaire d'évaluer la précision des paramètres dérivés des images satellites à haute résolution spatiale pour effectuer le suivi des prairies.

L'objectif de ce chapitre est double : il vise à (1) déterminer le ou les paramètre(s) dérivés de séries temporelles d'images de télédétection à haute résolution spatiale le(s) plus adapté(s) pour estimer la biomasse (Partie 2.1), et (2) évaluer les mêmes paramètres pour identifier trois types de pratiques agricoles associées aux prairies, c'est-à-dire le pâturage, la fauche et l'exploitation mixte de ces deux pratiques (Partie 2.2).

Ce chapitre est dédié exclusivement aux séries d'images optiques, les paramètres dérivés des images étant directement mis en relations avec les mêmes paramètres mesurés au sol.

## 2.1. Évaluation de paramètres dérivés d'une série temporelle optique à haute résolution spatiale pour estimer la biomasse des prairies

---

---

### CONTENTS

2.1.1	Introduction . . . . .	71
2.1.2	Méthodologie . . . . .	71
2.1.2.1	Les données . . . . .	71
2.1.2.2	Traitement statistique des données . . . . .	72
2.1.2.3	Calcul de la quantité d'herbe disponible . . . . .	73
2.1.3	Résultats et discussion . . . . .	73
2.1.3.1	Comparaison des paramètres dérivés des images de télédétection et des relevés <i>in situ</i> . . . . .	73
2.1.3.2	Validation du modèle de régression . . . . .	75
2.1.3.3	Application : estimation du stock d'herbe à l'échelle d'une exploitation agricole . . . . .	75
2.1.4	Conclusion . . . . .	76

---

**Abstract :** *In many regions, a decrease in grasslands and change in their management, which are associated with agricultural intensification, have been observed in the last half-century. Such changes in agricultural practices have caused negative environmental effects that include water pollution, soil degradation and biodiversity loss. Moreover, climate-driven changes in grassland productivity could have serious consequences for the profitability of agriculture. The aim of this study was to assess the ability of remotely sensed data with high spatial resolution to estimate grassland biomass in agricultural areas. A vegetation index, namely the Normalized Difference Vegetation Index (NDVI), and two biophysical variables, the Leaf Area Index (LAI) and the fraction of Vegetation Cover (fCOVER) were computed using five SPOT images acquired during the growing season. In parallel, ground-based information on grassland growth was collected to calculate biomass values. The analysis of the relationship between the variables derived from the remotely sensed data and the biomass observed in the field shows that LAI outperforms NDVI and fCOVER to estimate biomass ( $R^2$  values of 0.68 against 0.30 and 0.50, respectively). The squared Pearson correlation coefficient between observed and estimated biomass using LAI derived from SPOT images reached 0.73. Thus, we conclude that monitoring of grass reserves can be realized using biomass values estimated from remote sensing data.*

Le contenu de cette partie a été soumis dans l'article suivant :  
**P. Dusseux**, L. Hubert-Moy., T. Corpetti and F. Vertès.  
*Evaluation of SPOT imagery for the estimation of grassland biomass.*  
International Journal of Applied Earth Observation  
& Geoinformation, 2014 (*en révision*).

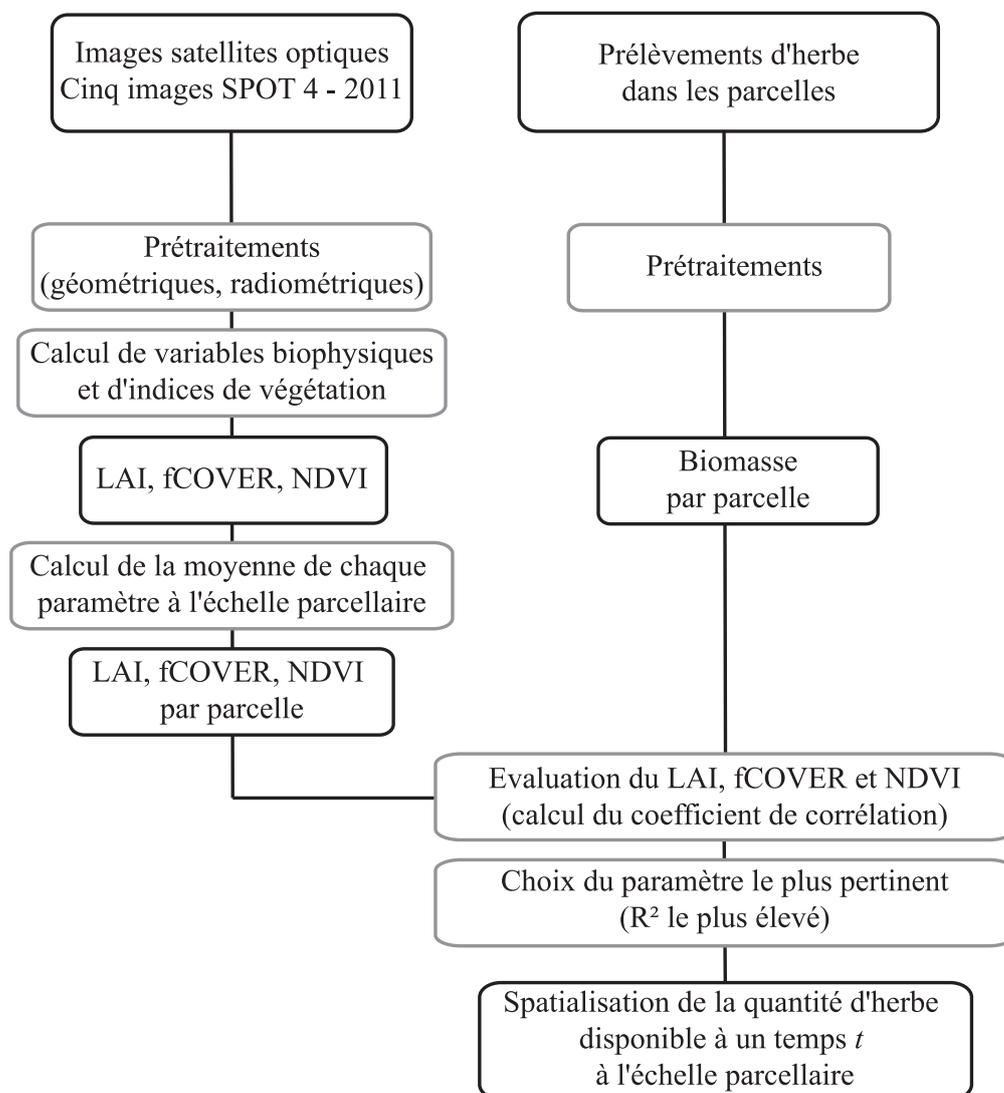


Figure 2.1 – Méthodologie générale appliquée pour l'évaluation de paramètres dérivés de données de télédétection optiques pour l'estimation de la biomasse

### 2.1.1. Introduction

Cette partie porte sur l'évaluation de paramètres dérivés de données de télédétection pour estimer la biomasse des couverts prairiaux en vue de connaître le stock d'herbe disponible à un temps  $t$  à l'échelle de l'exploitation agricole, la connaissance du nombre de jours d'herbe disponible dans les parcelles constituant une aide pour l'exploitant pour gérer ses prairies : il sait alors où mettre les animaux à pâturer, quelle(s) parcelle(s) faucher, quelle(s) parcelle(s) fertiliser, etc.

La biomasse peut être estimée à partir d'images satellites en utilisant des indices de végétation comme le NDVI ou des variables biophysiques comme le LAI et le fCOVER [Grant *et al.* 2012, Edirisinghe *et al.* 2011, Lu 2006]. Les progrès récents effectués dans le domaine de la télédétection, en termes de précision et de fréquence d'acquisition des données et dans le contexte des futures missions d'observation de la Terre *Venus* et *Sentinel-2*, des opportunités se présentent pour assurer un meilleur suivi des états de surface de la couverture végétale parmi lesquelles les prairies. L'exploitation de séries temporelles intra-annuelles d'images calibrées et validées avec des campagnes de terrain pendant la saison végétative de la prairie devrait permettre d'effectuer un suivi opérationnel des couverts prairiaux. En attendant la mise en orbite de ses nouveaux capteurs il est possible de constituer des séries temporelles d'images à partir de données acquises par plusieurs capteurs actuellement opérationnels afin de préparer l'exploitation des données de ces nouveaux capteurs.

Ainsi, les objectifs de cette partie sont (1) d'étudier les relations entre les paramètres dérivés d'une série temporelle d'images optiques à haute résolution spatiale et des mesures de biomasse collectées sur le terrain pour estimer la biomasse, (2) de déterminer quel est le paramètre le plus approprié pour l'estimation de la biomasse et (3) d'évaluer la possibilité de calculer l'herbe disponible à l'échelle de l'exploitation agricole par télédétection.

Pour cela, nous avons acquis une série de cinq images SPOT 4 et nous avons tout d'abord étudié la relation entre le NDVI, le LAI et le fCOVER dérivés de ces images et la biomasse mesurée sur le terrain. Cela a permis de mettre en évidence le paramètre le plus pertinent pour estimer la biomasse par télédétection. Ensuite, les valeurs de biomasse mesurées à partir de relevés effectués sur le terrain et les valeurs de biomasse estimées par télédétection ont été comparées. Cela nous permettra ensuite d'estimer le stock d'herbe disponible à l'échelle de l'exploitation agricole (Figure 2.1).

*Ce travail a été réalisé en collaboration avec Françoise Vertès de l'INRA-SAS Quimper qui a supervisé le protocole de traitement des données sur la biomasse et Paul Salaun de la Communauté d'Agglomération de Lannion-Trégor, comité des bassins versants de la Lieue de Grève qui a réalisé les relevés d'herbe in situ pour quantifier la biomasse au sol.*

### 2.1.2. Méthodologie

#### 2.1.2.1. Les données

Afin d'estimer la biomasse par télédétection, nous avons utilisé une série de cinq images satellites SPOT 4 acquises entre mars et octobre 2011 (Tableau 1.6, page 48). Ces images satellites ont été choisies car leurs dates d'acquisition étaient proches des dates de mesures de biomasse collectées sur le terrain (de 2 à 11 jours d'écart) (Tableau 2.1). Afin de réduire les erreurs résultant du capteur et

des conditions d'acquisition, ces images ont été corrigées des effets radiométriques, atmosphériques et géométriques. Ensuite, trois paramètres décrivant la couverture végétale, le NDVI, le LAI et le fCOVER ont été dérivés des images, les deux derniers paramètres ayant été obtenus en appliquant le modèle de transfert radiatif PROSAIL (section 1.4.1.1, page 47).

Les mesures de biomasse ont été collectées sur une dizaine de parcelles chaque mois (section 1.4.2.5, page 61). Les valeurs de biomasse moyenne des prairies varient tout au long de la période végétative (0.7, 0.68, 1.7, 0.9 et 1.3 t MS/ha pour mars, avril, mai, août et octobre, respectivement). La croissance de l'herbe débute mi-mars dans l'ouest de la France, mai et juin sont les mois où la croissance de la végétation est la plus vive avant une diminution de la production de biomasse pendant la saison estivale.

Tableau 2.1 – Dates de collecte des mesures de biomasse et dates d'acquisition des images satellites

Biomass collection date	DOY*	Image acquisition date	DOY*
March 17 2011	76	March 21 2011	80
April 11 2011	101	April 22 2011	112
May 20 2011	140	May 23 2011	143
June 23 2011	174	-	-
August 02 2011	214	August 10 2011	222
October 13 2011	286	October 15 2011	288

\*Day Of Year

### 2.1.2.2. Traitement statistique des données

Un modèle de régression a été utilisé pour évaluer dans quelle mesure la biomasse peut être estimée à partir de paramètres dérivés d'images satellites. La moitié environ des mesures de biomasse collectées sur le terrain (22/37 soit 60%) a été utilisée pour évaluer leur relation avec les données de télédétection. Cette sélection des mesures s'explique par le fait que les paramètres dérivés des images satellites ont été calculés à l'échelle de la parcelle (section 1.4.1.3, page 52) alors que les mesures de biomasse ont été collectées à une échelle intra-parcellaire correspondant à une zone en défens d'une superficie de  $2m^2$  (Figure 2.2).

Ainsi, toutes les mesures de biomasse calculées à partir des relevés effectués sur le terrain ne peuvent pas être mise en relation avec les paramètres dérivés des données de télédétection, la hauteur et la densité de la végétation entre la zone en défens et l'ensemble de la parcelle n'étant pas similaires. Les mesures *in situ* représentatives de l'état de surface de la parcelle dans son ensemble ont été identifiées à l'aide de calendriers agricoles indiquant les dates d'entrée et de sortie des animaux dans les parcelles.

Sur les 22 mesures disponibles, 15 (2/3 du total) ont été utilisées pour construire le modèle de régression entre les paramètres estimés à partir des données de télédétection (NDVI, LAI et fCOVER) et les mesures de biomasse *in situ*, sept échantillons (1/3 du total) ayant été utilisés pour évaluer le modèle. Le coefficient de détermination ( $R^2$ ) a été calculé pour évaluer la précision du modèle.

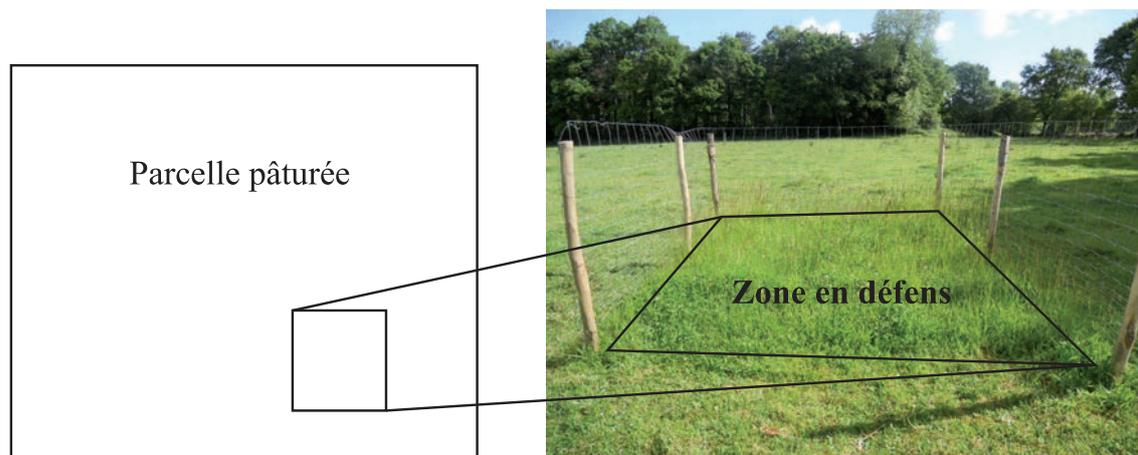


Figure 2.2 – Zone en défens pour la collecte de la biomasse

### 2.1.2.3. Calcul de la quantité d'herbe disponible

Le calcul de la quantité  $Q$  d'herbe disponible dans les parcelles a été effectué en prenant en compte les besoins alimentaires des animaux et les ressources en herbe disponibles pour le pâturage (équation 2.1) [Arvalis 2011, Delaby *et al.* 2001] :

$$Q = \frac{\text{biomass} * \text{Surface}}{\text{LSU} * \text{animal\_needs}}, \quad (2.1)$$

où le terme *biomass* est la biomasse mesurée ou estimée, exprimée en tonnes de matière sèche (MS)/ha, *Surface* correspond à la superficie de chaque parcelle en hectare, *LSU* (LiveStock Unit = Unité de Gros Bétail (UGB)) est l'unité de référence comptabilisant le bétail de différentes espèces et de différents âges sur la base de leurs besoins nutritionnels ou alimentaires, et *animal\_needs* correspond à une valeur constante indiquant les besoins alimentaires des animaux exprimé en kg de MS/UGB/jour.

## 2.1.3. Résultats et discussion

### 2.1.3.1. Comparaison des paramètres dérivés des images de télédétection et des relevés *in situ*

La figure 2.3 illustre les résultats des modèles de régression linéaire appliqués pour analyser la relation entre les paramètres dérivés des images de télédétection et la biomasse mesurée à partir des données *in situ*.

Les modèles de régression montrent des  $R^2$  de 0.30, 0.68 et 0.50 pour le NDVI, le LAI et le fCOVER, respectivement. Ainsi, le LAI apparaît comme le paramètre le plus pertinent pour estimer la biomasse. En outre, on peut observer que la valeur de NDVI correspondant à la valeur de biomasse la plus élevée reste inférieure à 0.6. Ce résultat confirme que le NDVI évolue de façon non linéaire avec l'état de surface des couverts végétaux et la biomasse [Edirisinghe *et al.* 2011, Viña *et al.* 2011, Huete *et al.* 1985, Carlson & Ripley 1997], saturant sur les surfaces végétales denses [Huete *et al.* 1997]. Des études ont aussi montré que pour des taux de couverture végétale supérieurs à 60%, les indices

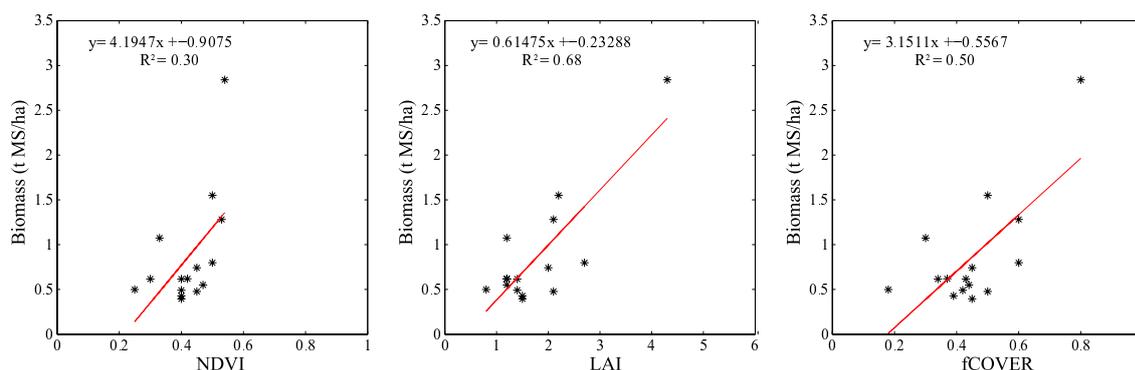


Figure 2.3 – Régressions et coefficients de détermination ( $R^2$ ) calculés entre les valeurs de NDVI, LAI et fCOVER dérivés des images de télédétection et les mesures de biomasses *in situ* (t MS/ha)

de végétation utilisant le proche infrarouge sont insensibles aux changements liés à la végétation [Gitelson *et al.* 2002, Glenn *et al.* 2008, Wu *et al.* 2007, Diaz & Blackburn 2003]. Ainsi, la précision de l'estimation de la biomasse de couverts végétaux denses sera plus faible en utilisant le NDVI qu'en utilisant des variables biophysiques. En outre, ces dernières offrent l'avantage de pouvoir être mesurées directement au sol, contrairement au NDVI, pour lequel la relation avec les paramètres de surface est empirique. De plus, ces indices de végétation, relativement simples et rapides à calculer, présentent l'inconvénient de simplifier l'information : deux types de végétation différents avec le même taux de couverture peuvent présenter des valeurs d'indices différentes, tandis que deux types de végétation différents avec des taux de couverture différents peuvent avoir des valeurs d'indices similaires. Par ailleurs, au sein d'un même type de végétation, les taux de couverture peuvent être similaires mais les valeurs d'indices différentes alors qu'inversement les taux de couverture végétale peuvent être différents pour des valeurs d'indices similaires [Jacquemoud & Baret 1990]. En d'autres termes, pour une même valeur d'indice de végétation, le LAI et le fCOVER peuvent avoir des valeurs différentes. Enfin, des études ont montré que le NDVI est sensible aux effets du sol et de l'atmosphère [Montandon & Small 2008, Henebry 1993, Baret & Guyot 1991, Huete *et al.* 1985] et qu'il ne tient pas compte des caractéristiques des capteurs (largeurs des bandes spectrales, la position orbitale, etc.) ni du système d'enregistrement [Jiang *et al.* 2006, Franke *et al.* 2006, Jacquemoud & Baret 1990, Baret *et al.* 1989]. De ce fait, un même indice de végétation dérivé de deux capteurs différents aura potentiellement des valeurs différentes. Ainsi, l'estimation de la biomasse à partir d'une relation simple basée sur un indice de végétation ne peut pas être considérée comme linéaire et généralisable et ne peut donc pas produire des estimations de biomasse aussi précises que des variables biophysiques.

De plus, l'analyse de la corrélation entre les paramètres dérivés des images de télédétection et la biomasse mesurée au sol montre des résultats différents pour les deux variables biophysiques ( $R^2=0.68$  pour le LAI et 0.5 pour le fCOVER). Ceci s'explique par le fait que le fCOVER renseigne sur la fraction de couverture végétale verte alors que le LAI, représentant la surface foliaire par unité de surface, apporte de l'information sur la densité du couvert végétal [Jacquemoud *et al.* 2009, Lecerf *et al.* 2008]. Ainsi, sur un sol avec une couverture végétale faible (repousses, végétation éparses ou sénescence, etc.) les valeurs de fCOVER peuvent être élevées alors que pour cette même surface les valeurs de LAI resteront faibles ce qui sous-tend que le couvert végétal n'est pas particulièrement dense. Par conséquent, le LAI apparaît comme la variable la plus adaptée pour l'estimation de la biomasse.

### 2.1.3.2. Validation du modèle de régression

La biomasse a été estimée sur les sept parcelles retenues pour la validation à partir du modèle de régression linéaire construit avec la biomasse mesurée et le LAI dérivé des images SPOT. Le coefficient de détermination obtenu est assez élevé puisqu'il atteint 0.73 (Figure 2.4). Ainsi, il est raisonnable de considérer que la biomasse peut être estimée sur l'ensemble du bassin versant en utilisant le LAI dérivé de données de télédétection (Figure 2.5-a). Ce modèle pourrait être amélioré en augmentant le nombre de mesures *in-situ*, notamment pendant les périodes où la végétation est dense. L'utilisation d'images satellites à très haute résolution spatiale (1 à 2m) pourrait améliorer l'estimation de la biomasse, cette dernière ayant été collectées à une échelle intra-parcellaire. Ainsi, tous les échantillons collectés seraient utilisables.

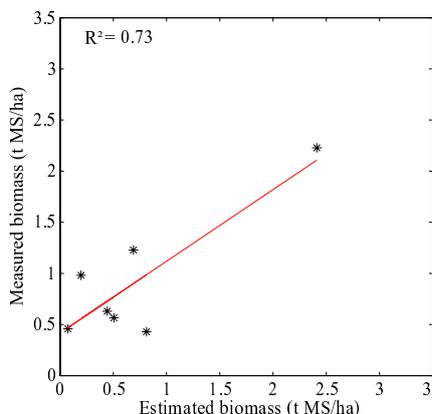


Figure 2.4 – Évaluation de la précision du modèle d'estimation de la biomasse à partir du LAI dérivé d'images de télédétection (t MS/ha)

### 2.1.3.3. Application : estimation du stock d'herbe à l'échelle d'une exploitation agricole

La biomasse a été estimée en tonnes de matière sèche (MS) /ha à l'échelle parcellaire sur l'ensemble du bassin versant en prenant en compte la superficie de chacune des parcelles (Figure 2.5-a), puis elle a été convertie en kg de MS (Figure 2.5-b). Ensuite, les besoins journaliers du troupeau ont été calculés par exploitation en prenant en compte la taille du troupeau (en UGB) et les besoins alimentaires de chaque animal (quantité d'herbe ingérée) estimés à environ 17kg de MS/UGB/jour [Arvalis 2011, Delaby *et al.* 2001]. La figure 2.5-c illustre la spatialisation de la biomasse par parcelle à chacune des dates auxquelles les images ont été acquises et ce pour l'exploitation agricole prise en exemple (ferme pilote) et la figure 2.5-d montre le stock d'herbe disponible en nombre de jours. Cette estimation a été réalisée sur une exploitation ayant 95ha de prairies et un UGB de 155.

Pour cette ferme pilote, les prairies présentent 68 jours de stock d'herbe (de pâturage) en mai. Ainsi, les besoins alimentaires du troupeau seront largement satisfaits et certaines parcelles peuvent être fauchées. La même situation peut être observée en octobre (50 jours de pâturage). Des enquêtes ont été réalisées sur cette exploitation afin de valider ces conclusions : trois coupes ont été effectuées au cours de la saison végétative de la prairie, la première début juin, la seconde mi-juillet et la dernière mi-octobre. Ainsi, le nombre de jour de pâturage (stock d'herbe) estimé à partir de données de télédétection est cohérent avec les pratiques qui ont été réalisées sur les parcelles.

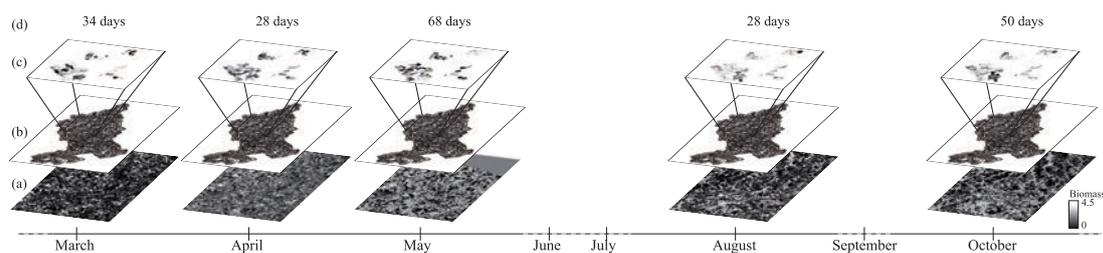


Figure 2.5 – Spatialisation de la biomasse estimée : à partir de chaque image satellite (a), à l'échelle parcellaire sur tout le bassin versant (b), à l'échelle parcellaire pour une ferme pilote (c) et le stock d'herbe estimé pour cette ferme pilote (d)

#### 2.1.4. Conclusion

Dans cette partie, nous avons évalué la capacité des images SPOT à estimer la biomasse des prairies. L'analyse statistique des relations entre des paramètres dérivés d'images de télédétection, à travers un indice de végétation (le NDVI) et deux variables biophysiques (le LAI et le fCOVER), et la biomasse mesurée à partir de relevés effectués sur le terrain a montré que le LAI est la variable la plus pertinente pour estimer la biomasse des prairies avec un  $R^2$  de 0.68 contre 0.3 et 0.5 pour le NDVI et le fCOVER, respectivement. Ainsi, le  $R^2$  obtenu entre la biomasse mesurée et la biomasse estimée en utilisant le LAI dérivé des images SPOT est de 0.73. En conséquence, nous pouvons en déduire que la biomasse peut raisonnablement être estimée à l'échelle d'un bassin versant ou d'une région en utilisant des données de télédétection optiques à haute résolution spatiale. Nous avons enfin montré que les données de télédétection peuvent aussi être utilisées pour estimer à l'échelle d'une exploitation à un temps  $t$  la quantité d'herbe disponible dans les parcelles de prairies pour alimenter le bétail.

## 2.2. Évaluation de paramètres dérivés d'une série temporelle optique à haute résolution spatiale pour discriminer des pratiques agricoles sur des prairies

---

---

### CONTENTS

2.2.1	Introduction . . . . .	79
2.2.2	Méthodologie . . . . .	79
2.2.2.1	Les données . . . . .	79
2.2.2.2	Mesure de la dissimilarité . . . . .	80
2.2.2.3	Classification des données . . . . .	82
2.2.3	Résultats et discussion . . . . .	82
2.2.3.1	Analyse des données . . . . .	82
2.2.3.2	Analyse de la dissimilarité . . . . .	87
2.2.3.3	Comparaison des paramètres dérivés des données observées <i>in situ</i> et des données de télédétection . . . . .	87
2.2.4	Conclusion . . . . .	94

---

**Abstract :** *The major decrease in grassland surfaces associated with changes in their management that has been observed in many regions of the Earth during the last half century has major impacts on environmental and socio-economic systems. This study focuses on the identification of grassland management practices in an intensive agricultural watershed located in Brittany, France, by analyzing the intra-annual dynamics of the surface condition of vegetation using remotely sensed and field data. We studied the relationship between one vegetation index (NDVI) and two biophysical variables (LAI and fCOVER) derived from a series of three SPOT images on one hand and measurements collected during field campaigns achieved on 120 grasslands on the other. The results show that the LAI appears as the best predictor for monitoring grassland mowing and grazing. Indeed, because of its ability to characterize vegetation status, LAI estimated from remote sensing data is a relevant variable to identify these practices. LAI values derived from the SPOT images were then classified based on the K-Nearest Neighbor (KNN) supervised algorithm. The results points out that the distribution of grassland management practices such as grazing and mowing can be mapped very accurately (Kappa index = 0.82) at a field scale over large agricultural areas using a series of satellite images.*

Le contenu de cette partie a été publié dans l'article suivant :  
**P. Dusseux**, F. Vertès, T. Corpetti, S. Corgne and L. Hubert-Moy.  
*Agricultural practices in grasslands detected by spatial remote sensing.*  
Environmental Monitoring and Assessment, 2014.  
doi : 10.1007/s10661-014-4001-5

Annexe 1

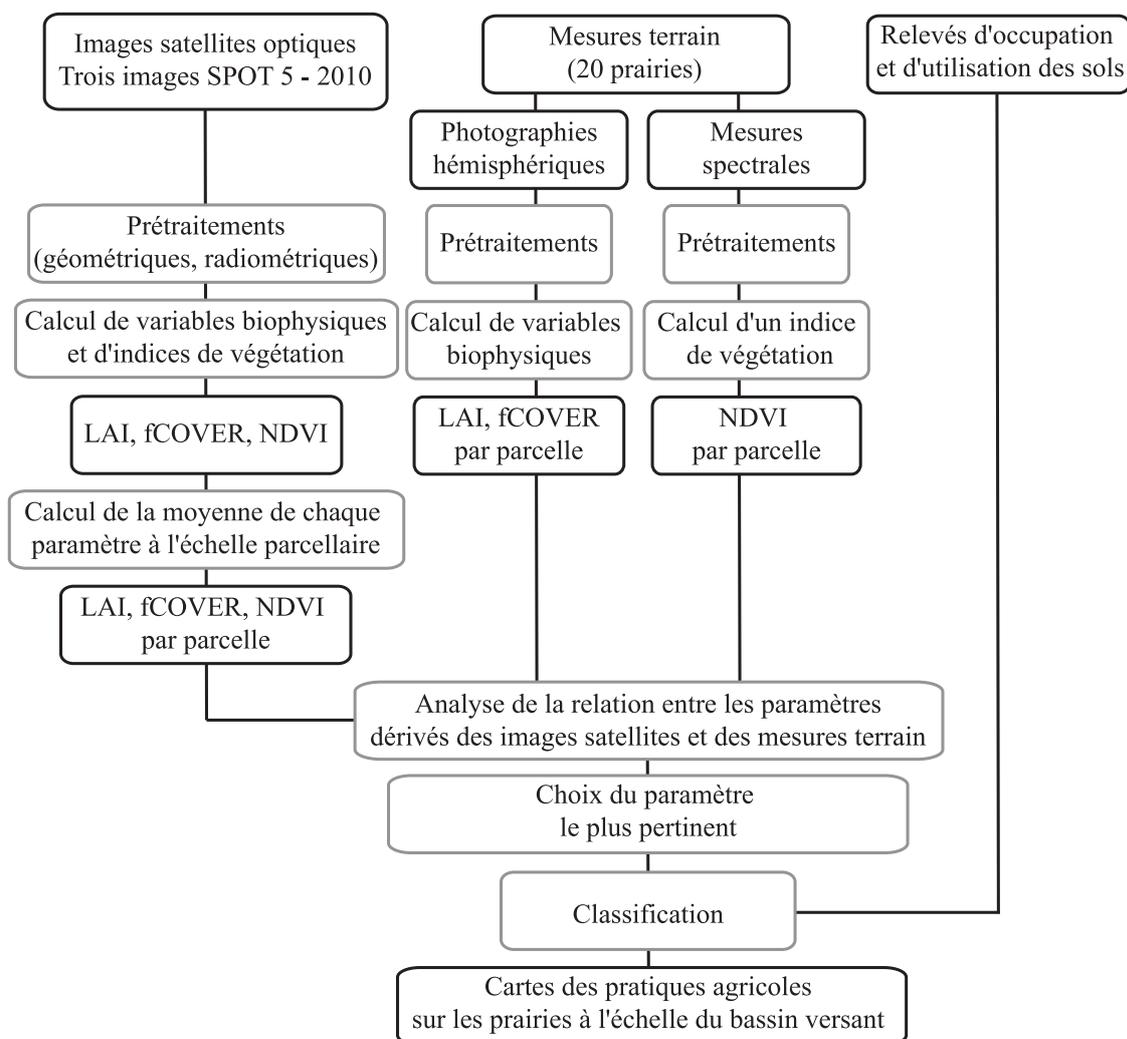


Figure 2.6 – Méthodologie générale appliquée pour l'évaluation de paramètres dérivés d'images satellites optiques pour le suivi des prairies

## 2.2.1. Introduction

Cette partie porte sur l'identification de pratiques agricoles réalisées sur les prairies à travers l'analyse de la dynamique intra-annuelle d'indices de végétation et de variables biophysiques dérivés d'une série temporelle d'images satellites décrivant l'état de surface de la végétation.

Alors que l'état de surface des parcelles recouvertes par de la végétation varie en fonction de leur utilisation, les pratiques agricoles peuvent être identifiées par l'analyse de la densité, de la hauteur et du taux de couverture de la végétation. Ainsi, suite au pâturage on observe une diminution de la densité, du taux de couverture et de la hauteur de la végétation qui peut être plus ou moins importante en fonction de son intensité (le sol pourra devenir visible en cas de sur-pâturage). Une fauche va quant à elle entraîner une baisse importante et rapide de la densité, du taux de couverture et de la hauteur de la végétation avec l'apparition du sol.

Le taux de couverture, la densité et la hauteur de la végétation peuvent être dérivés de données de télédétection à travers le calcul d'indices de végétation comme le NDVI ou l'estimation de variables biophysiques comme le LAI et le fCOVER qui ont montré leur intérêt pour l'étude de la croissance de la végétation, l'estimation de la biomasse et l'identification des pratiques agricoles [Edirisinghe *et al.* 2011, Jacquemoud *et al.* 2009, Lu 2006]. En effet, une augmentation de ces paramètres renseigne sur la croissance de la végétation, tandis que leur diminution apporte de l'information sur les pratiques agricoles effectuées sur les parcelles. Cependant, la relation entre l'état des couverts prairiaux et les pratiques agricoles effectuées sur les prairies n'a jamais encore été étudiée à partir de séries temporelles d'images de télédétection.

Ainsi, les objectifs de cette partie sont (1) d'étudier les relations entre les paramètres dérivés d'une série temporelle d'images optiques à haute résolution spatiale et des mesures collectées sur le terrain pour la description des couverts prairiaux, (2) de déterminer quel est le paramètre le plus approprié pour le suivi des prairies et (3) d'évaluer le potentiel des données de télédétection pour identifier les modes de gestion des prairies.

Afin d'atteindre ces objectifs, nous allons d'abord analyser la relation entre les données de télédétection, et plus précisément les paramètres qui en sont dérivés (en l'occurrence ici le NDVI, le LAI et le fCOVER), et ces mêmes paramètres estimés à partir de mesures effectuées sur le terrain. Puis, après avoir sélectionné le paramètre le plus pertinent parmi les trois paramètres étudiés, nous effectuerons une classification des trois modes de gestion des prairies que nous avons retenus pour cette étude (le pâturage, la fauche et l'exploitation mixte) à l'échelle de l'ensemble du site d'étude (Figure 2.6).

## 2.2.2. Méthodologie

### 2.2.2.1. Les données

Trois images enregistrées par le satellite SPOT 5, acquises au cours de l'année 2010, ont été utilisées pour identifier les pratiques agricoles sur le site d'étude (Tableau 1.6, page 48). L'information texturale contenue dans les images n'a pas été exploitée car leur résolution spatiale qui varie de 5m à 10m est trop faible au regard de la superficie moyenne des parcelles de prairie de la zone d'étude (moins de 1ha en moyenne) pour étudier l'hétérogénéité intra-parcellaire. En conséquence, seule l'information

spectrale a été traitée.

Parallèlement à l'acquisition des images satellites, des campagnes ont été réalisées sur le terrain afin de calibrer et valider leur traitement. Des relevés d'occupation des sols, des mesures sur la végétation (taux de couverture, hauteur de la végétation, profils spectraux et photographies hémisphériques) et des enquêtes chez les exploitants ont été réalisés (section 1.4.2, page 56). Plus précisément, des mesures spectrales et des photographies hémisphériques ont été prises sur une vingtaine de parcelles afin d'en dériver respectivement des valeurs de NDVI et des valeurs de LAI et de fCOVER. Les pré-traitements et traitements réalisés sur les images satellites et les mesures collectées sur le terrain ont été détaillés dans la section 1.4 (page 47).

Afin de comparer les données de télédétection et les données collectées sur le terrain, les mesures spectrales (et les NDVI qui en sont dérivés), les photographies hémisphériques (et les LAI et fCOVER qui en sont dérivés) ainsi que les échantillons extraits des images satellites ont été classés par parcelle, par date d'acquisition et selon l'état de surface des couverts végétaux, ce dernier dépendant des modes de gestion, de la hauteur du couvert végétal, du stade phénologique des plantes et du taux de couverture par la végétation. Trois états de surface ont été identifiés : l'état 1 (*S1*) correspondant à une végétation d'une hauteur inférieure à 10cm avec le sol apparent (taux de couverture par la végétation < 70%), l'état 2 (*S2*) correspondant à une végétation d'une hauteur comprise entre 10cm et 20cm (taux de couverture par la végétation > 90%) et l'état 3 (*S3*) correspondant à une hauteur de végétation supérieure à 20cm (taux de couverture = 100%) (Figure 2.7).

### 2.2.2.2. Mesure de la dissimilarité

Avant de réaliser l'analyse statistique de dissimilarité entre les différentes classes d'état de surface des couverts végétaux, les données ont été normalisées (centrées-réduites) afin de comparer leurs variations, indépendamment de leurs ordres de grandeur. Centrer-réduire une variable  $x$  consiste à soustraire son espérance  $\mu$  à chacune de ses valeurs initiales (centrer) et à diviser toutes ses valeurs par son écart-type  $\sigma$  :

$$x_{\text{centrée-réduite}} = \frac{x - \mu}{\sigma}. \quad (2.2)$$

Ainsi, une variable centrée-réduite a une espérance nulle, une variance et un écart-type égaux à 1.

Ensuite, pour quantifier la similarité/dissimilarité entre les différentes classes d'état de surface, une mesure de dissimilarité,  $D$ , a été calculée pour chaque paire de classes ( $x, y$ ), chacune étant représentée par un vecteur de  $n$  valeurs. Cette mesure s'écrit :

$$D = \sqrt{\sum_{i=1}^n |x_i - y_i|^2}. \quad (2.3)$$

La mesure de dissimilarité  $D$  correspond à la distance euclidienne entre deux valeurs ou séries de  $n$  valeurs,  $x_i$  et  $y_i$ . Cette mesure est utilisée pour obtenir une discrimination quantitative entre les classes d'état de surface pour chacune des valeurs dérivées des mesures de terrain et des données de télédétection. Plus la distance euclidienne augmente plus les classes seront dissociables.

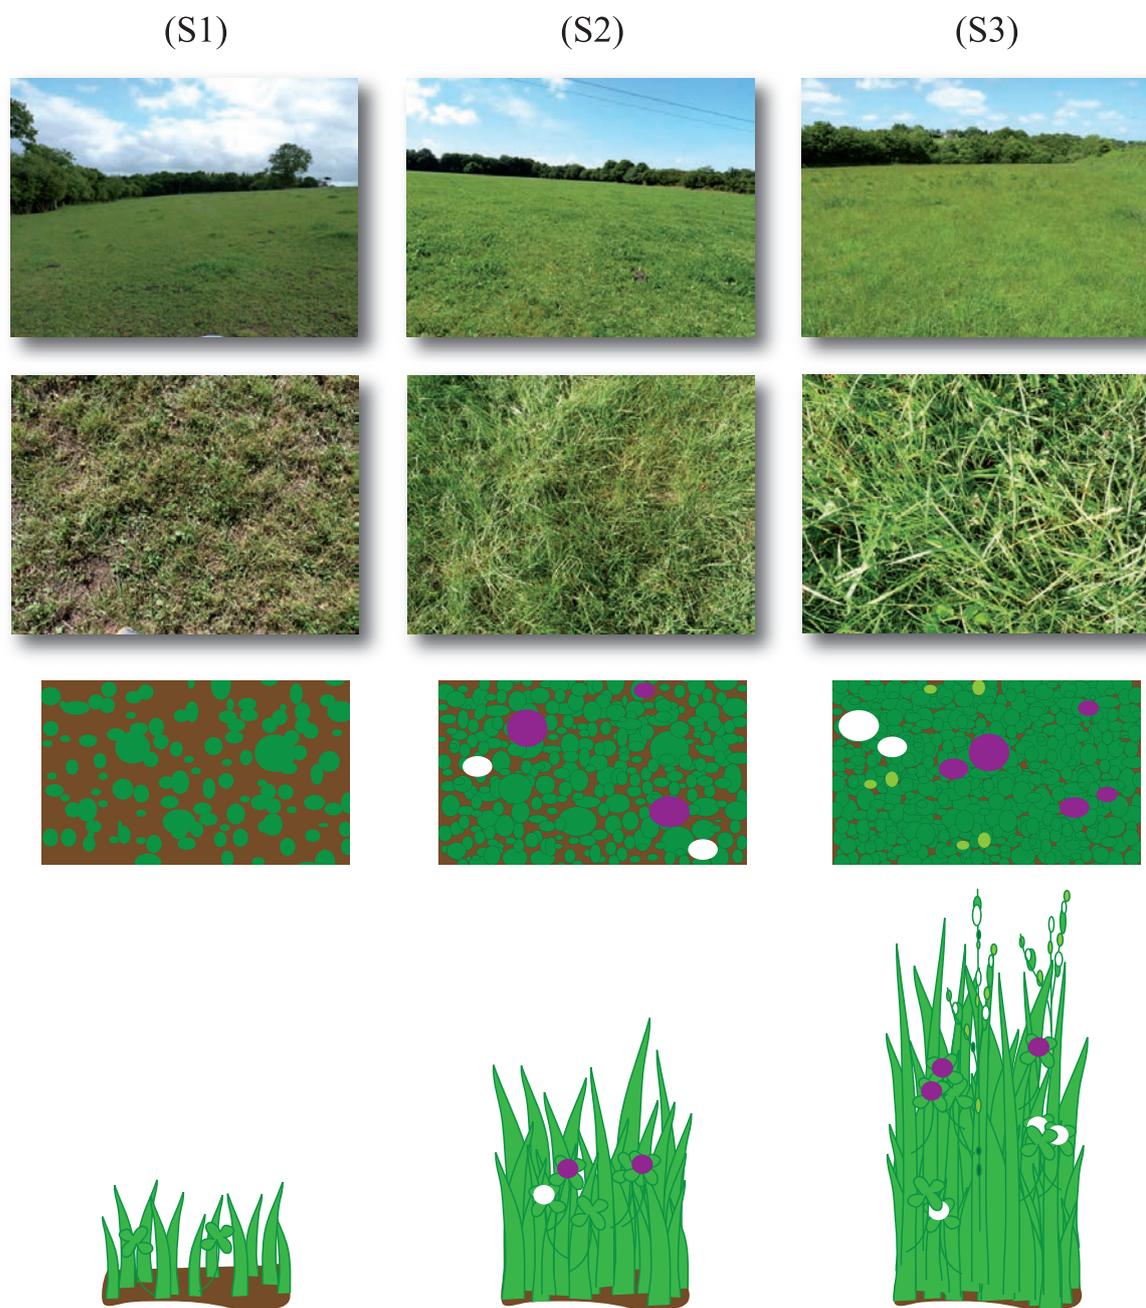


Figure 2.7 – Classification des prairies selon trois états de surface : *S1* correspondant à une végétation d'une hauteur inférieure à 10cm avec le sol apparent (taux de couverture par la végétation < 70%), *S2* correspondant à une végétation d'une hauteur comprise entre 10cm et 20cm (taux de couverture par la végétation > 90%) et *S3* correspondant à une hauteur de végétation supérieure à 20cm (taux de couverture = 100%)

### 2.2.2.3. Classification des données

Les données utilisées dans cette partie, à savoir le NDVI estimé à partir des mesures spectrales effectuées sur le terrain, le LAI et le fCOVER dérivés des photographies hémisphériques et ces mêmes variables dérivées des images satellites ont été classés selon deux approches de classification : une approche non supervisée utilisant l'algorithme k-means [MacQueen 1967] et une approche supervisée utilisant la méthode des  $k$  plus proches voisins (KNN) [Cover & Hart 1967b].

En premier lieu, les profils temporels, estimés sur 7 parcelles à partir des relevés terrain ont été classés avec les deux approches de classification pour (1) évaluer la séparabilité entre les classes et (2) évaluer la performance de ces approches de classification. Ensuite, la méthode supervisée KNN a été utilisée pour classer les profils dérivés des images satellites. Plusieurs échantillonnages ont été constitués pour évaluer l'impact de leur taille sur la précision des résultats de la classification : ainsi, après avoir classé les 102 parcelles pour lesquels des informations sur les modes de gestion et l'état de la couverture végétale ont été collectées en utilisant le plus petit échantillonnage disponible (7 parcelles), la classification a été réalisée à l'échelle de l'ensemble du bassin versant (environ 3000 parcelles) en utilisant le plus grand échantillonnage disponible (102 parcelles).

Enfin, l'indice du Kappa ( $K$ ), très couramment utilisé pour évaluer les erreurs de prédiction en télédétection, a été calculé pour déterminer la précision des classifications [Congalton 1991]. La significativité de cet indice a été évalué par le test du  $Chi^2$  [Stigler 2008].

## 2.2.3. Résultats et discussion

### 2.2.3.1. Analyse des données

#### 2.2.3.1.1. Les mesures spectrales et les NDVI qui en sont dérivés

Les profils spectraux issus des mesures *in situ* réalisées avec le spectroradiomètre montrent des formes similaires qui suivent le profil théorique de réflectance de la végétation (Figure 1.7, page 19). Ces profils semblent toutefois discriminables grâce à l'amplitude des valeurs observée dans le proche infrarouge principalement (Figure 2.8-a). Cependant, d'après [Price 1994], au sein d'une classe représentant le même couvert végétal, les mesures spectrales peuvent varier. En effet, des couverts végétaux différents peuvent montrer des réflectances similaires alors qu'un même type de couvert végétal peut montrer des réflectances différentes (Figure 2.8-b).

Afin d'étudier la relation entre les mesures spectrales *in situ* et les données de télédétection, les mesures spectrales ont été classées par mois d'acquisition et selon l'état de surface de la végétation (Figure 2.9). Ce classement montre que les profils spectraux de la classe  $S1$ , classe où le sol est apparent, ont des réflectances plus importantes dans le rouge qui est sensible aux effets du sol et des réflectances plus faibles dans le proche infrarouge que les profils spectraux des classes  $S2$  et  $S3$ , ce qui s'explique par l'influence du sol sous-jacent et la densité de la végétation [Jensen 2000].

L'indice NDVI a ensuite été calculé à partir des mesures spectrales dégradées à la résolution des données SPOT (Figure 1.29, page 59). Le tableau 2.2 illustre les valeurs moyennes de NDVI par mois d'acquisition et par classe d'état de surface. Les valeurs de NDVI de la classe  $S1$  sont en moyenne inférieures aux valeurs de NDVI de la classe  $S2$  qui sont elles aussi en moyenne inférieures aux valeurs de NDVI de la classe  $S3$ . Cet indice traduit bien l'état du couvert végétal (augmentation avec la densité, la hauteur et l'activité chlorophyllienne de la végétation). Cependant, d'après la figure 2.10,

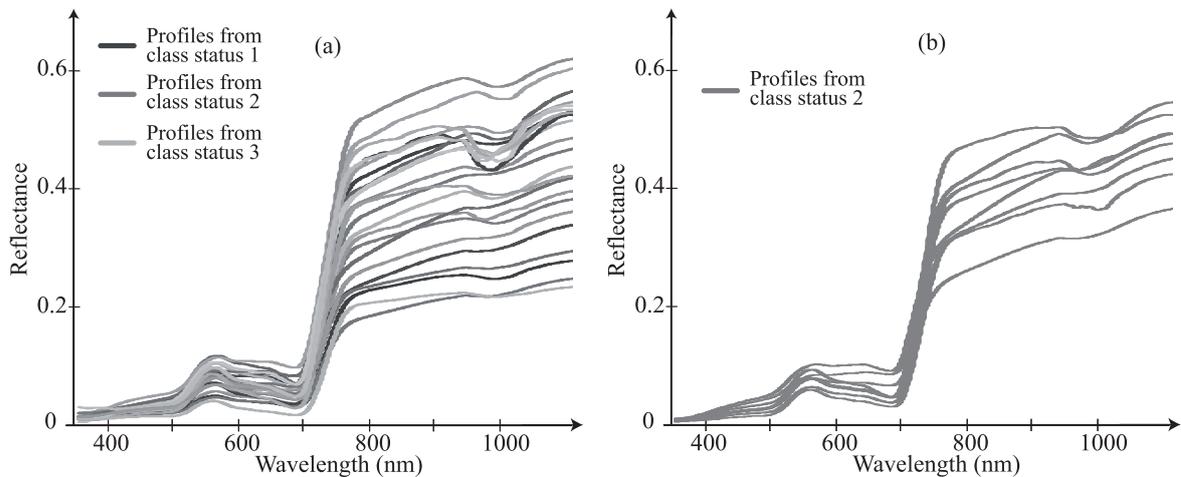


Figure 2.8 – Mesures spectrales collectées avec le spectroradiomètre ASD FieldSpec3 : forme similaire des profils (a) et variabilité intra-classe (b)

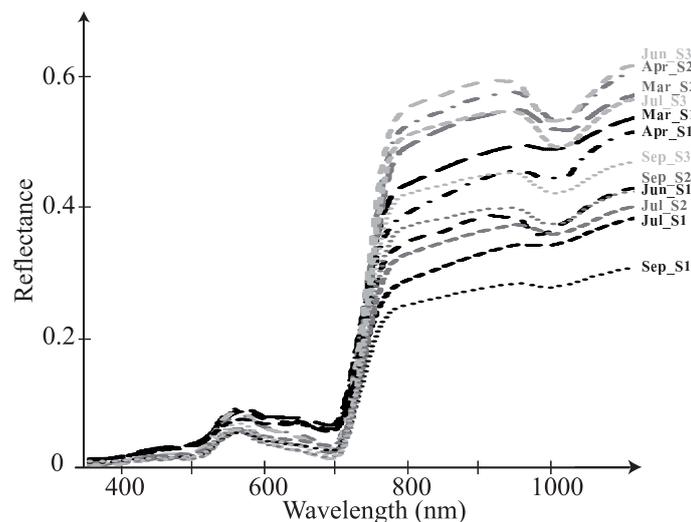


Figure 2.9 – Mesures spectrales classées par mois d'acquisition et selon l'état de surface de la végétation ( $S1$  = état de surface 1,  $S2$  = état de surface 2 et  $S3$  = état de surface 3)

on peut observer des valeurs de NDVI similaires pour des états de surface différents. Ceci concorde avec des observations effectuées dans plusieurs études qui ont déjà montré que la relation entre le NDVI et l'état de la végétation est non linéaire [Edirisinghe *et al.* 2011, Viña *et al.* 2011, Huete *et al.* 1985, Carlson & Ripley 1997]. De plus, le NDVI sature sur une surface végétale dense, les indices de végétation utilisant le PIR étant insensibles aux changements liés à la végétation pour des taux de couverture végétale supérieurs à 60% [Gitelson *et al.* 2002, Glenn *et al.* 2008, Wu *et al.* 2007, Diaz & Blackburn 2003, Huete *et al.* 1997]. Ceci explique les confusions possibles entre les différents états de surface analysés avec les profils de NDVI.

Tableau 2.2 – NDVI moyen par classe et par mois d'acquisition dérivé des mesures spectrales *in situ*

	11/03/2010	21/04/2010	15/06/2010	07/07/2010	21/09/2010
<b>Status 1</b>	0.71	0.72	0.68	0.66	0.58
<b>Status 2</b>	0.85	0.81	-	0.77	0.67
<b>Status 3</b>	-	-	0.83	0.89	0.73

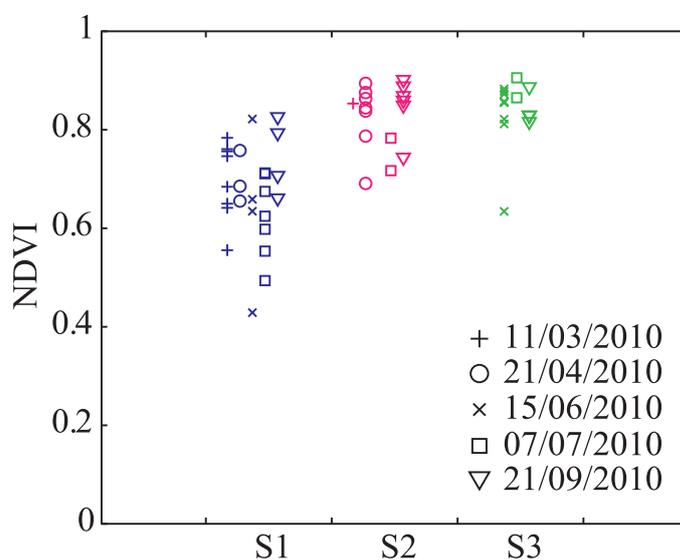


Figure 2.10 – NDVI par classe et par mois d'acquisition dérivé des mesures spectrales *in situ*

### 2.2.3.1.2. LAI et fCOVER estimés à partir des photographies hémisphériques

Le tableau 2.3 illustre les valeurs moyennes de LAI et de fCOVER obtenues à partir des photographies hémisphériques par mois d'acquisition et par classe d'état de surface. Les valeurs de ces deux variables biophysiques pour la classe S1 sont en moyenne inférieures aux valeurs de la classe S2 qui sont elles aussi en moyenne inférieures aux valeurs de la classe S3. Ces variables traduisent bien l'état du couvert végétal comme l'illustre la figure 2.11 (augmentation avec la densité et la hauteur de la végétation).

Tableau 2.3 – LAI et fCOVER moyen par classe et par mois d'acquisition dérivés des photographies hémisphériques prises sur le terrain

	LAI			fCOVER		
	Status 1	Status 2	Status 3	Status 1	Status 2	Status 3
11/03/2010	1.5	3.4	-	0.6	0.87	-
26/05/2010	1.2	3.1	6.1	0.58	0.85	0.99
15/06/2010	2	3.4	5.4	0.7	0.84	0.91
07/07/2010	2.1	3.4	5	0.76	0.84	0.92
02/08/2010	1.9	3.6	5.7	0.78	0.84	0.97
21/09/2010	-	2.6	5.5	-	0.81	0.96
08/11/2010	1.7	3	4.9	0.8	0.82	0.97

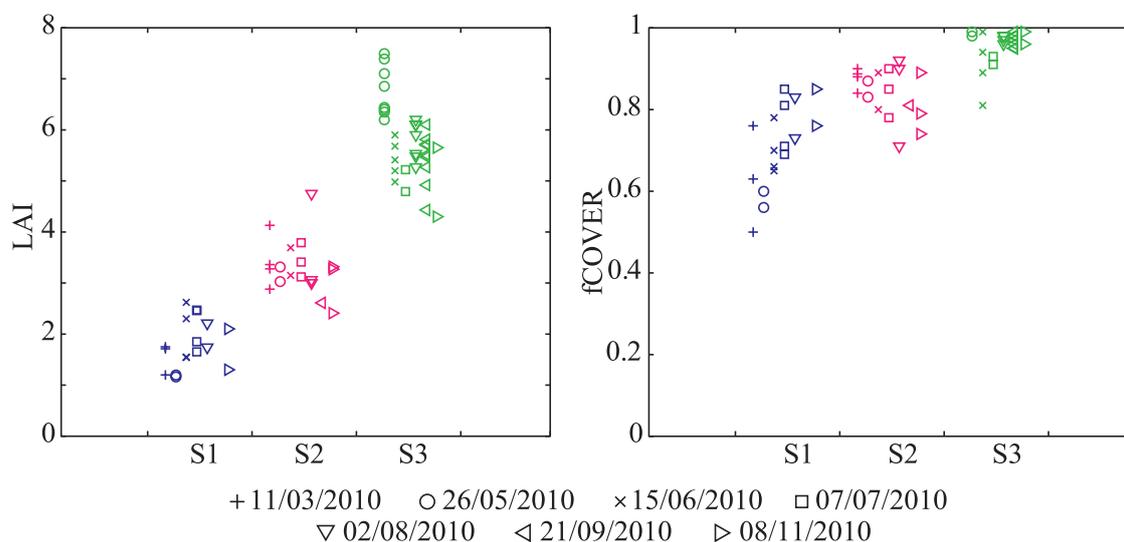


Figure 2.11 – LAI et fCOVER par classe et par mois d'acquisition dérivés des photographies hémisphériques prises sur le terrain

### 2.2.3.1.3. NDVI, LAI et fCOVER dérivés des images satellites

Les réflectances des images satellites sélectionnées pour l'échantillonnage (en fonction de l'échantillonnage terrain) ont été classées par mois d'acquisition et selon l'état de surface de la végétation (Figure 2.12). Ce classement montre que les profils spectraux de la classe *S1*, classe où le sol est apparent, ont des réflectances plus importantes dans le rouge qui est sensible aux effets du sol et des réflectances plus faibles dans le proche infrarouge que les profils spectraux des classes *S2* et *S3*, ceci étant dû à l'influence du sol sous-jacent et à la densité de la végétation [Jensen 2000].

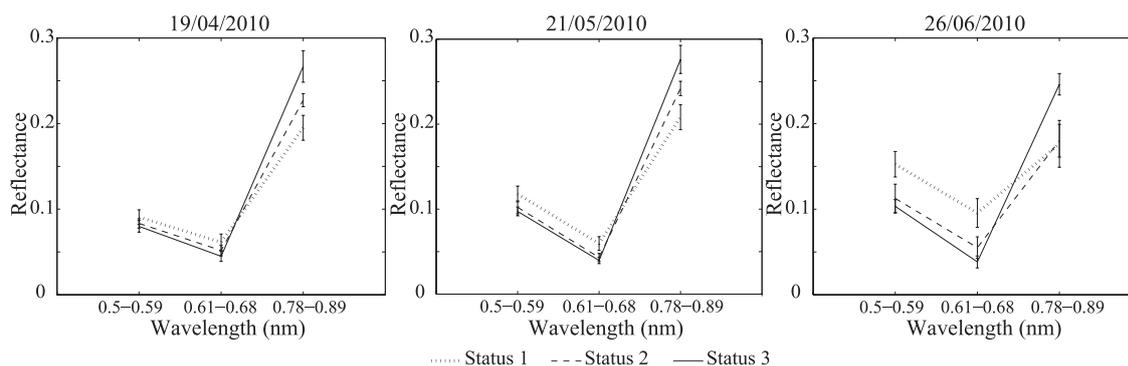


Figure 2.12 – Réflectances moyennes par classe et par mois d'acquisition dérivées des images satellites

Le tableau 2.4, qui illustre les valeurs moyennes de NDVI, LAI et de fCOVER par mois d'acquisition et par classe d'état de surfaces, montre que les valeurs de ces trois paramètres pour la classe *S1* sont inférieures aux valeurs de la classe *S2* qui sont elles aussi inférieures aux valeurs de la classe *S3*. Ces paramètres traduisent bien l'état du couvert végétal comme l'illustre par la figure 2.13 (augmentation avec la densité et la hauteur de la végétation).

Tableau 2.4 – NDVI, LAI et fCOVER moyen par classe et par mois d'acquisition dérivés des images satellites

				LAI		
				S1	S2	S3
19/04/2010				0.7	1.3	2.4
21/05/2010				1.5	2.8	5.3
26/06/2010				1.3	3	4.7
				fCOVER		
				S1	S2	S3
19/04/2010				0.51	0.68	0.72
21/05/2010				0.43	0.72	0.83
26/06/2010				0.39	0.72	0.85

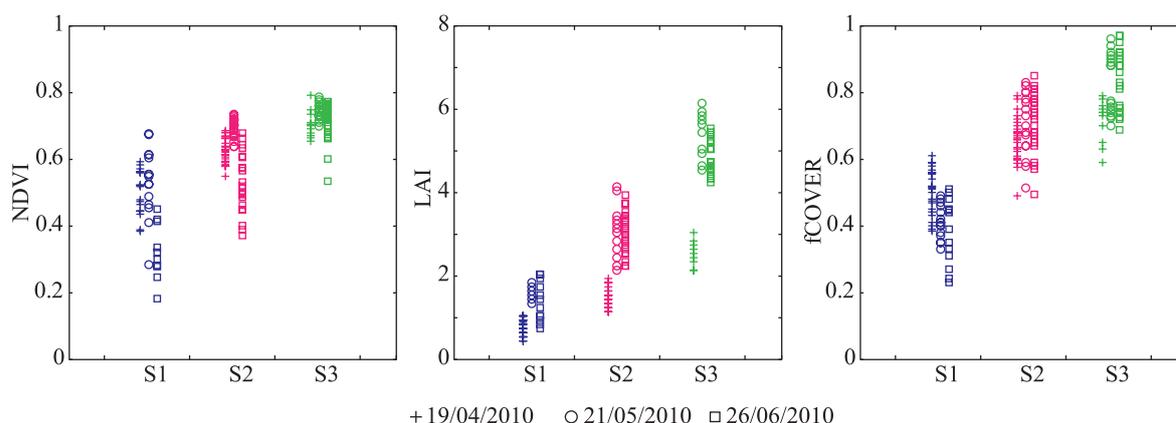


Figure 2.13 – NDVI, LAI et fCOVER par classe et par mois d’acquisition dérivés des images satellites

### 2.2.3.2. Analyse de la dissimilarité

La mesure de dissimilarité entre les trois classes d’état de surface et pour chaque mois d’acquisition de données est présentée dans le tableau 2.5 pour le NDVI dérivé des mesures spectrales *in situ* et pour le LAI et le fCOVER estimés à partir des photographies hémisphériques, et dans le tableau 2.6 pour les NDVI, LAI et fCOVER dérivés des images satellites. Globalement,  $D$  est plus élevé entre les classes d’état de surface  $S1$  et  $S3$ , traduisant une grande différence entre ces deux classes. Ainsi, logiquement il est plus aisé de distinguer des parcelles avec des états de surface bien distincts alors que l’identification des parcelles ayant des états de surface intermédiaires sera plus difficile à effectuer.

### 2.2.3.3. Comparaison des paramètres dérivés des données observées *in situ* et des données de télédétection

#### 2.2.3.3.1. Pour le suivi du couvert végétal

La comparaison des valeurs de NDVI, LAI et fCOVER dérivées des images satellites et celles estimées à partir des mesures *in situ* montre des différences (Figure 2.14). En effet, les valeurs de NDVI issues des images SPOT ( $NDVI_{spot}$ ) sont comprises entre 0.2 et 0.8 alors que les valeurs de NDVI issues des mesures spectrales *in situ* ( $NDVI_{spectral}$ ) sont toutes supérieures à 0.6. On peut faire la même observation pour les valeurs de fCOVER : les valeurs dérivées des images SPOT ( $fCOVER_{spot}$ ) sont comprises entre 0.2 et 0.8 alors que celles qui ont été estimées à partir des photographies hémisphériques ( $fCOVER_{hemis}$ ) sont supérieures à 0.5. Les valeurs de LAI issues des images satellites ( $LAI_{spot}$ ) et des photographies hémisphériques ( $LAI_{hemis}$ ) varient dans les mêmes intervalles. Ainsi, le LAI montre une plus grande corrélation entre les valeurs dérivées des images et celles estimées à partir des mesures *in situ* ( $R^2 = 0.94$ ) que le NDVI ( $R^2 = 0.90$ ) et le fCOVER ( $R^2 = 0.77$ ).

Ainsi, comme cela a été souligné dans la section 2.1.3.1 (page 73) le NDVI est sensible aux effets du sol et de l’atmosphère et ne tient pas compte des caractéristiques des capteurs [Jacquemoud & Baret 1990, Baret *et al.* 1989]. De ce fait, une même surface enregistrée par deux capteurs différents peut correspondre à deux NDVI différents. De plus, la relation entre le NDVI et l’état de surface est empirique car le NDVI ne représente pas directement des paramètres mesurables au sol, plusieurs

Tableau 2.5 – Mesure de dissimilarité  $D$  entre les trois classes d'état de surface pour le NDVI, LAI et fCOVER dérivés des mesures *in situ*

				<b>LAI</b>			
				<b>S1-S2</b>	<b>S2-S3</b>	<b>S1-S3</b>	
				<b>11/03/2010</b>	1.3	-	-
				<b>26/05/2010</b>	1.5	4.8	11.6
				<b>15/06/2010</b>	0.8	1.5	4.4
				<b>07/07/2010</b>	0.7	0.9	3.1
				<b>02/08/2010</b>	1	1.7	5.3
				<b>21/09/2010</b>	-	3.1	-
				<b>08/11/2010</b>	0.6	1.5	4

				<b>fCOVER</b>			
				<b>S1-S2</b>	<b>S2-S3</b>	<b>S1-S3</b>	
				<b>11/03/2010</b>	4.7	-	-
				<b>26/05/2010</b>	5.6	1.5	13
				<b>15/06/2010</b>	1.7	0.4	3.6
				<b>07/07/2010</b>	0.5	0.4	1.8
				<b>02/08/2010</b>	0.3	1.4	3
				<b>21/09/2010</b>	-	1.8	-
				<b>08/11/2010</b>	0	2.2	2.2

				<b>NDVI</b>		
				<b>S1-S2</b>	<b>S2-S3</b>	<b>S1-S3</b>
<b>11/03/2010</b>	0.6	-	-			
<b>21/04/2010</b>	1	-	-			
<b>15/06/2010</b>	-	-	2.9			
<b>07/07/2010</b>	1.6	1.9	7			
<b>21/09/2010</b>	1	0.5	2.9			

Tableau 2.6 – Mesure de dissimilarité  $D$  entre les trois classes d'état de surface pour le NDVI, LAI et fCOVER dérivés des images satellites

				<b>LAI</b>			
				<b>S1-S2</b>	<b>S2-S3</b>	<b>S1-S3</b>	
				<b>19/04/2010</b>	0.1	0.5	1.1
				<b>21/05/2010</b>	0.7	2.5	5.7
				<b>26/06/2010</b>	1.1	1.1	4.6

				<b>fCOVER</b>			
				<b>S1-S2</b>	<b>S2-S3</b>	<b>S1-S3</b>	
				<b>19/04/2010</b>	1	0.1	1.6
				<b>21/05/2010</b>	3	0.4	5.7
				<b>26/06/2010</b>	3.9	0.6	7.6

				<b>NDVI</b>		
				<b>S1-S2</b>	<b>S2-S3</b>	<b>S1-S3</b>
<b>19/04/2010</b>	0.58	0.3	1.7			
<b>21/05/2010</b>	1	0.1	1.9			
<b>26/06/2010</b>	2.5	1.9	8.9			

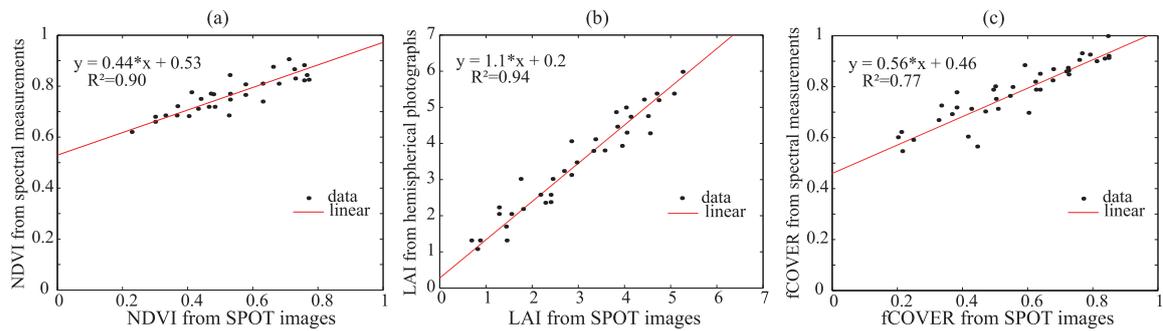


Figure 2.14 – Régression linéaire entre les valeurs de NDVI estimées à partir des images satellites SPOT ( $NDVI_{spot}$ ) et les valeurs de NDVI dérivées des mesures spectrales *in situ* ( $NDVI_{spectral}$ ) (a) ; entre les valeurs de LAI estimées à partir des images satellites SPOT ( $LAI_{spot}$ ) et les valeurs de LAI dérivées des photographies hémisphériques ( $LAI_{hemis}$ ) (b) ; entre les valeurs de fCOVER estimées à partir des images satellites SPOT ( $fCOVER_{spot}$ ) et les valeurs de fCOVER dérivées des photographies hémisphériques ( $fCOVER_{hemis}$ ) (c)

études ayant montré une relation non linéaire entre le NDVI et l'état de la végétation [Edirisinghe *et al.* 2011, Viña *et al.* 2011, Huete *et al.* 1985, Carlson & Ripley 1997] et cela est également illustré en figure 2.15 sur nos données. Ainsi, pour des taux de couverture végétale supérieurs à 60%, les indices de végétation utilisant le PIR, tel que le NDVI, sont insensibles aux changements liés à la végétation [Gitelson *et al.* 2002, Glenn *et al.* 2008, Wu *et al.* 2007, Diaz & Blackburn 2003], car ils saturent sur les surfaces végétales denses [Huete *et al.* 1997]. Par conséquent, la différence de précision entre un indice de végétation comme le NDVI et des variables biophysiques pour discriminer les différents états du couvert végétal s'explique par la sensibilité des indices de végétation aux perturbations liées aux propriétés optiques du couvert.

Enfin, la relation entre les fCOVER estimés à partir des photographies hémisphériques et ceux dérivés des images SPOT est plus faible que celle du LAI. Ceci s'explique par le fait que le fCOVER représente la couverture végétale au sol. Ainsi, une végétation couvrante mais peu dense aura des valeurs de fCOVER élevées (de 0.5 à 0.8) et des valeurs de LAI faibles (de 1 à 2), puisque le LAI décrit la densité du couvert végétale. Par conséquent, au regard des comparaisons entre les paramètres dérivés des données observées *in situ* et des données de télédétection, le LAI apparaît comme la variable la plus adaptée à la description et au suivi de la végétation. Nous avons donc utilisé cette variable pour l'identification des pratiques agricoles réalisées sur les prairies.

### 2.2.3.3.2. Pour l'identification des pratiques agricoles

Comme les états de surface du couvert végétal varient selon les modes de gestion des prairies, nous avons cherché à identifier trois modes de gestion en utilisant les séries temporelles de LAI mesurées *in situ* et celles dérivées des images satellites : le pâturage, la fauche et l'exploitation mixte.

En premier lieu, l'échantillonnage qui a été utilisé pour classer les pratiques agricoles est composé de profils temporels de LAI extraits de sept parcelles sélectionnées parmi les vingt parcelles pour lesquelles des mesures *in situ* sont disponibles. Il s'agit des sept parcelles pour lesquelles les mesures *in situ* sont les plus complètes. La figure 2.16 montre les profils temporels de LAI dérivés des photographies hémisphériques et des images SPOT correspondant aux à ces parcelles pour les trois classes de mode de gestion étudiés. D'après ces graphiques, on peut constater que :

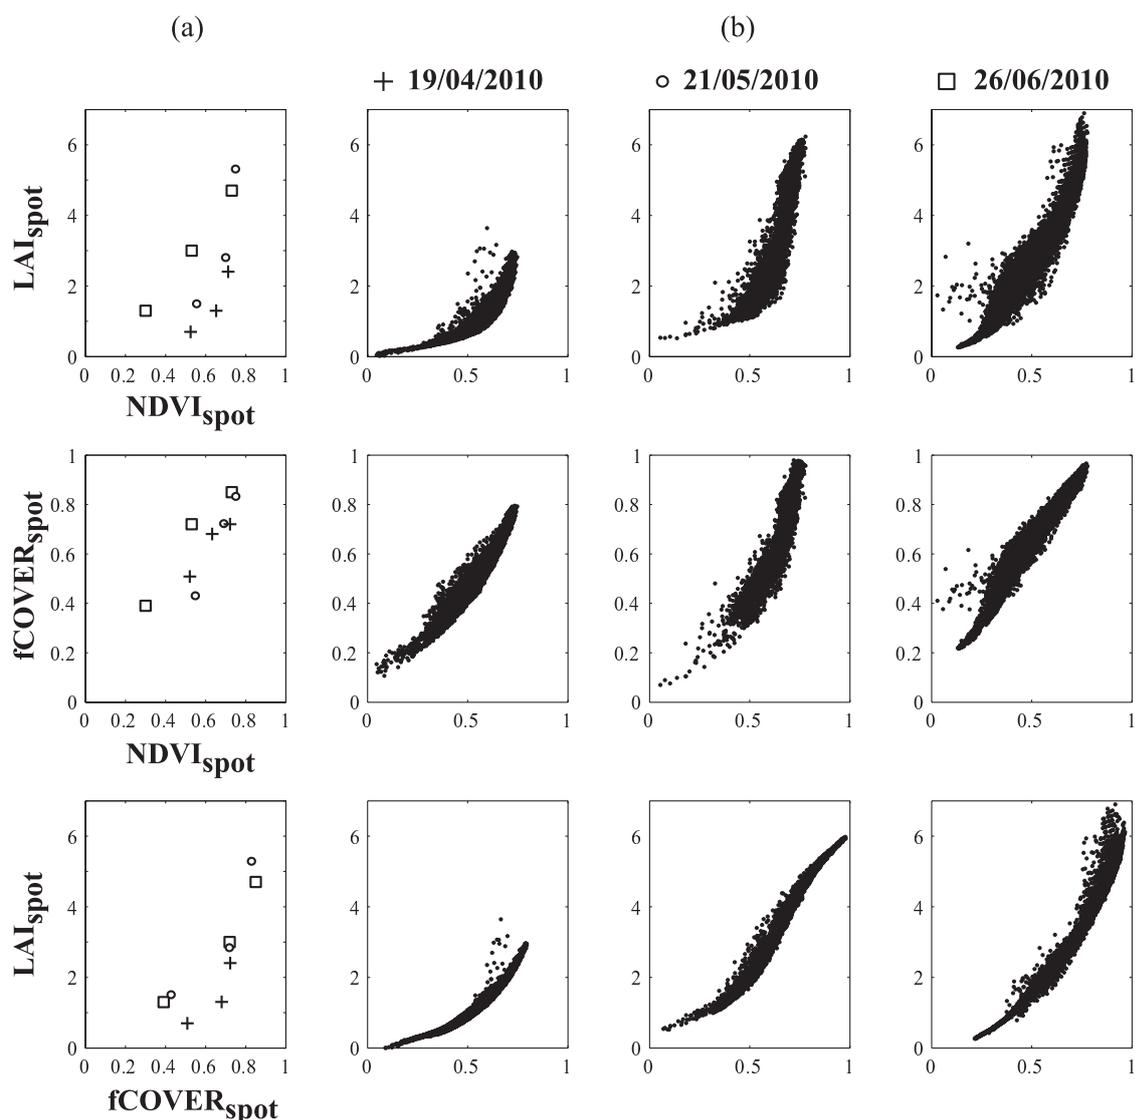


Figure 2.15 – Relation entre les valeurs moyennes de NDVI, LAI et fCOVER estimées à partir des images satellites SPOT ( $NDVI_{spot}$ ,  $LAI_{spot}$  et  $fCOVER_{spot}$ ) par classe et par mois d'acquisition (a) et relation entre les valeurs de NDVI, LAI et fCOVER estimées à partir des images satellites SPOT ( $NDVI_{spot}$ ,  $LAI_{spot}$  et  $fCOVER_{spot}$ ) par mois d'acquisition (b). Il apparaît clairement sur ces graphiques que les relations mises en jeu sont non linéaires

- (a) Les profils temporels de LAI estimés à partir des photographies hémisphériques (7 points par profils) correspondant au pâturage et à la fauche montrent des valeurs différentes en particulier en Mai et Juin (DOY : 146 et 166, respectivement) (Figure 2.16, a-2). Il s'agit d'une fauche, et on observe pour les parcelles concernées une baisse plus importante de la biomasse que pour les parcelles exploitées en pâturage. En outre, alors que les classes pâturage et exploitation mixte présentent une variance intra-classe relativement importante sur toute la période végétative, la classe fauche présente une faible variance intra-classe exceptée en septembre (DOY : 264). En effet, au moment de l'acquisition de l'image, certaines parcelles avaient déjà été fauchées

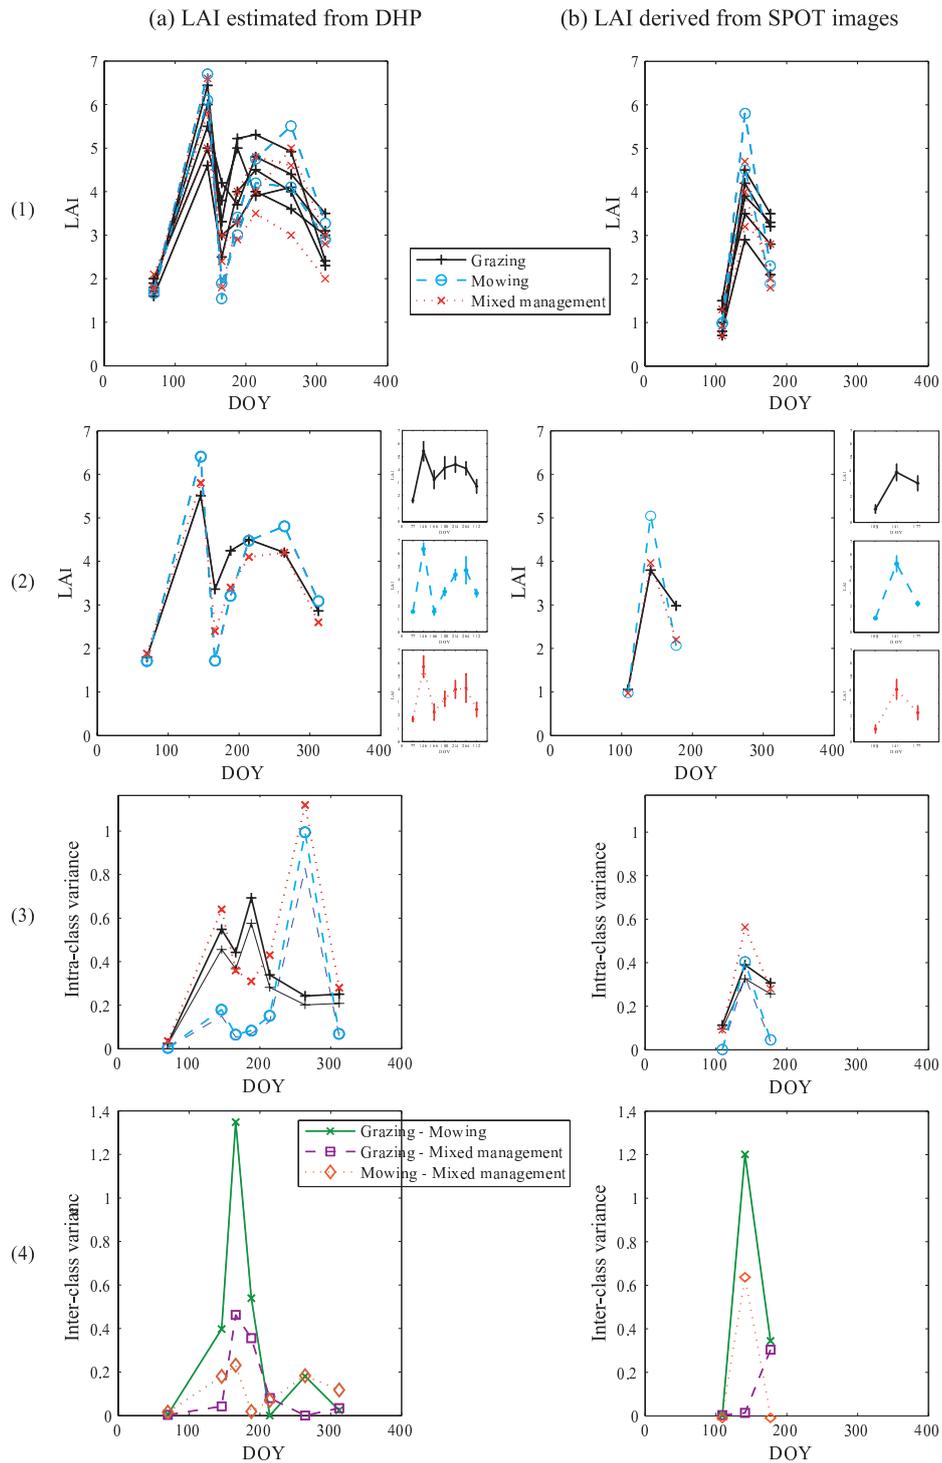


Figure 2.16 – Profils temporels de LAI estimés à partir des photographies hémisphériques (a-1), moyenne (a-2), variance intra-classe (a-3) et inter-classe (a-4) ; Profils temporels de LAI estimés à partir des images satellites (a-1), moyenne (a-2), variance intra-classe (a-3) et inter-classe (a-4)

et d'autres pas encore (Figure 2.16, a-3). Par ailleurs, il apparaît que les dates de Mai, Juin et Juillet (DOY : 146, 166 et 188, respectivement) sont très intéressantes pour distinguer les pratiques de pâturage de celles de la fauche (Figure 2.16, a-4). En revanche, la variance inter-classe est relativement faible d'une part, entre le pâturage et l'exploitation mixte et entre la fauche et l'exploitation mixte, d'autre part. La forte proximité des profils de l'exploitation mixte avec ceux des deux autres classes (pâturage et fauche) s'explique par le fait qu'elle est un mélange de ces deux modes de gestion.

- (b) Les profils temporels de LAI dérivés des images SPOT (3 points par profils), montrent des valeurs différentes pour les classes pâturage et fauche en Mai (DOY : 141) (Figure 2.16, b-2). Globalement, la variance intra-classe est faible pour les trois modes de gestion (Figure 2.16, b-3). Le mois de mai apparaît comme la période d'acquisition la plus favorable pour distinguer le pâturage de la fauche (Figure 2.16, b-4). Cependant, la variance inter-classe est relativement faible entre le pâturage et l'exploitation mixte d'une part, et entre la fauche et l'exploitation mixte, d'autre part.

Ainsi, nous avons pu observer des profils temporels de LAI différents selon les modes gestion. Le pâturage et la fauche montrent des profils vraiment différents alors que l'exploitation mixte présente des profils intermédiaires entre ces deux modes de gestion. Au cours d'une saison, plusieurs pratiques sont réalisées sur une même parcelle : des pâturages successifs exclusivement, des fauches exclusivement ou une alternance entre pâturage et fauche. La physionomie et l'évolution temporelle des parcelles exclusivement pâturées se différencie clairement de celles des parcelles exclusivement fauchées. Les parcelles à utilisation mixte présentent quant à elles des physionomies et une évolution temporelle intermédiaire. Pour pouvoir les discriminer, des informations très régulières sur la végétation sont requises. Ainsi, avec le nombre d'images satellites utilisées dans cette étude et leur date d'acquisition, seuls le pâturage et la fauche peuvent être discriminés. En effet, les profils temporels dérivés des images satellites illustrent la première période de la saison végétative des prairies et ne permettent pas d'identifier l'exploitation mixte. Par conséquent, seuls le pâturage et la fauche ont été considérés pour l'étape de classification.

En deuxième lieu, les résultats de la classification des profils temporels de LAI correspondant aux parcelles pâturées et fauchées (Figure 2.17-a) montrent un Kappa de 0.7 pour les profils de LAI estimés à partir des mesures *in situ* et un Kappa de 0.6 pour les profils de LAI dérivés des images satellites. Cette différence peut être expliquée par le fait que les profils dérivés des images satellites sont seulement composés de 3 valeurs (trois dates d'acquisition) alors que les profils estimés à partir des photographies hémisphériques sont composés de 7 valeurs. Ainsi, logiquement, plus le nombre de points utilisés pour construire les profils temporels est important, plus l'identification des modes de gestion est précise. De plus, la méthode de classification utilisée ne prend en compte aucune connaissance *a priori*. Nous avons donc testé une méthode de classification supervisée d'abord sur un échantillonnage de parcelles dont le mode de gestion est connu (Figure 2.17-b) puis sur l'ensemble des parcelles du bassin versant (Figure 2.17-c). Nous avons obtenu un premier Kappa de 0.83 pour la classification des 102 parcelles pour lesquelles les pratiques agricoles avaient été relevées sur le terrain. Ces parcelles ont ensuite été utilisées comme entraînement pour une part (2/3) et comme validation (1/3) pour l'autre part pour classer l'ensemble des parcelles de prairies du bassin versant. Un Kappa de 0.82 a été obtenu. Ainsi, avec une série de trois images satellites nous pouvons distinguer les prairies pâturées des prairies fauchées avec 80% d'exactitude. Cependant, pour identifier l'utilisation mixte, un nombre plus élevé d'images satellites pendant la saison végétative est nécessaire [Griffith *et al.* 2001].

	(a)		(b)		(c)																																																																																																											
<b>Classification method</b>	(a-1) Unsupervised classification: K-means	(a-2) Unsupervised classification: K-means	Supervised classification: K-nearest neighbor		Supervised classification: K-nearest neighbor																																																																																																											
<b>Data to classify</b>	LAI estimated from DHP: 7 fields	LAI derived from SPOT images: 7 fields	LAI derived from SPOT images: Around 100 fields (Field campaigns data)		LAI derived from SPOT images: Study site (Around 2000 fields)																																																																																																											
<b>Training set (Ground-truth data)</b>	-	LAI derived from SPOT images: 7 fields	LAI derived from SPOT images: 7 fields		LAI derived from SPOT images: 60 fields (Around 2/3 of field campaigns data)																																																																																																											
<b>Validation set</b>	LAI estimated from DHP: 7 fields	LAI derived from SPOT images: 7 fields	LAI derived from SPOT images: Around 100 fields (Field campaigns data)		LAI derived from SPOT images: 42 fields (Around 1/3 of field campaigns data)																																																																																																											
<b>Confusion matrix</b>	<table border="1"> <thead> <tr> <th rowspan="2">Ground truth</th> <th colspan="2">Classification</th> <th rowspan="2">TI</th> <th rowspan="2">Error O</th> </tr> <tr> <th>1</th> <th>2</th> </tr> </thead> <tbody> <tr> <th>1</th> <td>4</td> <td>1</td> <td>5</td> <td>0.2</td> </tr> <tr> <th>2</th> <td>0</td> <td>2</td> <td>2</td> <td>0</td> </tr> <tr> <th>T2</th> <td>4</td> <td>3</td> <td>7</td> <td></td> </tr> <tr> <th>Error C</th> <td>0</td> <td>0.5</td> <td></td> <td></td> </tr> </tbody> </table>	Ground truth	Classification		TI	Error O	1	2	1	4	1	5	0.2	2	0	2	2	0	T2	4	3	7		Error C	0	0.5			<table border="1"> <thead> <tr> <th rowspan="2">Ground truth</th> <th colspan="2">Classification</th> <th rowspan="2">TI</th> <th rowspan="2">Error O</th> </tr> <tr> <th>1</th> <th>2</th> </tr> </thead> <tbody> <tr> <th>1</th> <td>5</td> <td>0</td> <td>5</td> <td>0</td> </tr> <tr> <th>2</th> <td>1</td> <td>1</td> <td>2</td> <td>0.5</td> </tr> <tr> <th>T2</th> <td>6</td> <td>1</td> <td>7</td> <td></td> </tr> <tr> <th>Error C</th> <td>0.2</td> <td>0</td> <td></td> <td></td> </tr> </tbody> </table>	Ground truth	Classification		TI	Error O	1	2	1	5	0	5	0	2	1	1	2	0.5	T2	6	1	7		Error C	0.2	0			<table border="1"> <thead> <tr> <th rowspan="2">Ground truth</th> <th colspan="2">Classification</th> <th rowspan="2">TI</th> <th rowspan="2">Error O</th> </tr> <tr> <th>1</th> <th>2</th> </tr> </thead> <tbody> <tr> <th>1</th> <td>76</td> <td>2</td> <td>78</td> <td>0.02</td> </tr> <tr> <th>2</th> <td>4</td> <td>20</td> <td>24</td> <td>0.16</td> </tr> <tr> <th>T2</th> <td>80</td> <td>22</td> <td>102</td> <td></td> </tr> <tr> <th>Error C</th> <td>0.05</td> <td>0.08</td> <td></td> <td></td> </tr> </tbody> </table>	Ground truth	Classification		TI	Error O	1	2	1	76	2	78	0.02	2	4	20	24	0.16	T2	80	22	102		Error C	0.05	0.08			<table border="1"> <thead> <tr> <th rowspan="2">Ground truth</th> <th colspan="2">Classification</th> <th rowspan="2">TI</th> <th rowspan="2">Error O</th> </tr> <tr> <th>1</th> <th>2</th> </tr> </thead> <tbody> <tr> <th>1</th> <td>34</td> <td>0</td> <td>34</td> <td>0</td> </tr> <tr> <th>2</th> <td>2</td> <td>6</td> <td>8</td> <td>0.75</td> </tr> <tr> <th>T2</th> <td>36</td> <td>6</td> <td>42</td> <td></td> </tr> <tr> <th>Error C</th> <td>0.05</td> <td>0</td> <td></td> <td></td> </tr> </tbody> </table>	Ground truth	Classification		TI	Error O	1	2	1	34	0	34	0	2	2	6	8	0.75	T2	36	6	42		Error C	0.05	0		
Ground truth	Classification		TI	Error O																																																																																																												
	1	2																																																																																																														
1	4	1	5	0.2																																																																																																												
2	0	2	2	0																																																																																																												
T2	4	3	7																																																																																																													
Error C	0	0.5																																																																																																														
Ground truth	Classification		TI	Error O																																																																																																												
	1	2																																																																																																														
1	5	0	5	0																																																																																																												
2	1	1	2	0.5																																																																																																												
T2	6	1	7																																																																																																													
Error C	0.2	0																																																																																																														
Ground truth	Classification		TI	Error O																																																																																																												
	1	2																																																																																																														
1	76	2	78	0.02																																																																																																												
2	4	20	24	0.16																																																																																																												
T2	80	22	102																																																																																																													
Error C	0.05	0.08																																																																																																														
Ground truth	Classification		TI	Error O																																																																																																												
	1	2																																																																																																														
1	34	0	34	0																																																																																																												
2	2	6	8	0.75																																																																																																												
T2	36	6	42																																																																																																													
Error C	0.05	0																																																																																																														
<b>Kappa index</b>	0.7	0.6	0.83		0.82																																																																																																											
<b>p-value</b>	0.02	0.03	<0.005		<0.005																																																																																																											

Figure 2.17 – Procédure et évaluation des classifications

## 2.2.4. Conclusion

Dans cette partie nous avons évalué la relation entre des paramètres estimés à partir d'une série de trois images satellites SPOT et ces même paramètres directement mesurés au sol afin d'identifier les pratiques agricoles réalisées sur les prairies. L'analyse des relations entre ces paramètres a montré que le LAI est le paramètre le plus adapté pour le suivi des prairies. De plus, elle met aussi en évidence que les pratiques de pâturage et de fauche peuvent être discriminées en utilisant seulement trois images satellites de type SPOT bien distribuées pendant la saison végétative, à savoir une en mai, une en juin et une en juillet sur le site retenu pour cette étude, alors que l'identification du mode d'exploitation mixte des prairies nécessite un plus grand nombre d'images.

## Synthèse et conclusion du second chapitre

---

Dans ce chapitre, nous avons cherché à évaluer le potentiel de séries temporelles d'images optiques de télédétection pour estimer la biomasse et décrire l'état de surface de la végétation (hauteur, densité, homogénéité) dans des parcelles de prairies afin d'en identifier le mode de gestion. Les trois modes de gestion que nous avons cherché à identifier sont le pâturage, la fauche et l'exploitation mixte.

Des campagnes de terrain ont été réalisées mensuellement pour recueillir des mesures de biomasse et des données sur l'état de la végétation et la gestion des prairies. Pendant la saison végétative de 2010 et 2011, des mesures et observations ont été effectuées sur le terrain en même temps que l'acquisition d'images SPOT. Trois paramètres dérivés des images satellites optiques à haute résolution spatiale ont été évalués : l'indice de végétation NDVI (Normalized Difference Vegetation Index) et deux variables biophysiques, le LAI (Leaf Area Index) et le fCOVER (fraction of Vegetation Cover).

Les analyses statistiques que nous avons effectuées pour comparer la biomasse estimée à partir des relevés effectués sur le terrain et les paramètres dérivés des images de télédétection ont montré que le LAI est le paramètre le plus pertinent pour estimer la biomasse des prairies ( $R^2$  de 0.68 contre 0.3 et 0.5 pour le NDVI et le fCOVER, respectivement). Une corrélation avec un  $R^2$  de 0.73 a ainsi été obtenue entre la biomasse mesurée et la biomasse estimée à partir du LAI dérivé de cinq images SPOT. De ce fait, nous pouvons considérer que la biomasse peut être estimée avec une grande précision en utilisant des données de télédétection. De plus, nous avons aussi montré l'intérêt de ces données pour estimer le stock d'herbe disponible à l'échelle d'une exploitation agricole.

Ainsi, les données de télédétection pourraient être utilisées de façon opérationnelle pour aider les exploitants à gérer leurs prairies. La connaissance de la biomasse disponible à l'échelle de la parcelle sur l'ensemble de leur exploitation leur permettrait de répondre à un certain nombre de questions récurrentes parmi lesquelles : quelle parcelle pâturer en premier, laquelle faucher, la quantité d'herbe est-elle suffisante pour alimenter le bétail pour le mois qui vient, etc. Enfin, la biomasse des prairies, calculée à partir des images satellites, pourrait être utilisée comme données d'entrée dans des modèles de cultures tels que STICS [Brisson *et al.* 2003] afin d'améliorer l'estimation de la production des prairies en fonction des conditions climatiques par exemple. De plus, dans le contexte des futures missions d'observation de la Terre Ven $\mu$ s et Sentinel-2, une grande quantité d'images satellites avec des résolutions spatiales et temporelles élevées sera bientôt disponible, offrant de nouvelles perspectives pour le suivi intra-annuel des prairies. En effet, la modélisation de l'estimation de la biomasse des prairies pourrait être améliorée grâce à l'utilisation d'un nombre accru d'images satellites au cours d'une même année, ce qui permettrait de couvrir une plus grande diversité de prairies.

Les résultats obtenus montrent aussi que le LAI est le paramètre le plus pertinent pour décrire l'état de surface de la végétation des prairies, ce qui permet d'en identifier les modes de gestion ( $R^2$  de 0.94 contre 0.90 et 0.77 pour le NDVI et le fCOVER, respectivement). Le pâturage et la fauche peuvent être discriminés en utilisant une série limitée à trois images satellites à haute résolution spatiale. Cependant, pour identifier l'exploitation mixte des prairies (pâturage et fauche sur la même parcelle durant la saison végétative) un plus grand nombre d'images satellites est nécessaire. L'utilisation d'un nombre accru d'images satellites au cours d'une même année permettrait aussi d'envisager le suivi

## 2.2. *Évaluation de paramètres dérivés d'une série temporelle optique à haute résolution spatiale pour discriminer des pratiques agricoles sur des prairies*

---

de la fertilisation des prairies.

*En conséquence, au vu des résultats obtenus avec le LAI, seul ce paramètre sera utilisé dans les chapitres suivants pour identifier les prairies et caractériser leurs modes de gestion à partir de séries temporelles d'image optiques à haute résolution spatiale.*

# 3

## Exploitation de séries temporelles d'images satellites à haute résolution spatiale pour l'identification des prairies

### Sommaire

---

Introduction . . . . .	99
3.1 Analyse de séries temporelles d'images optiques à haute résolution spatiale pour l'identification des prairies . . . . .	101
3.2 L'apport de séries temporelles d'images radars pour l'identification des prairies . . . . .	111
Synthèse et conclusion du troisième chapitre . . . . .	137

---



## Introduction

---

Au cours des cinquante dernières années, une diminution importante des surfaces en prairies, associée à l'intensification agricole, a été observée dans de nombreuses régions du globe [Peeters 2009, Poudévigne & Alard 1997]. Ceci impacte les systèmes socio-économiques pour les stocks de fourrage mais aussi les systèmes environnementaux de différentes manières, allant de l'augmentation de la pollution de l'eau, à la dégradation des sols en passant par la perte de la biodiversité [Batáry *et al.* 2007, Vertès *et al.* 2007]. De plus, les prairies jouent un rôle fonctionnel important, notamment pour le stockage de carbone ou les flux de nitrates. Par exemple, le stockage de carbone diminue avec la baisse des surfaces en prairies alors que les flux de nitrates augmentent [Jérôme *et al.* 2014, Vertès *et al.* 2007, Arrouays *et al.* 2001].

Ainsi, dans ce contexte, l'identification des prairies est un enjeu important pour une agriculture durable. Cependant, à ce jour, il n'existe pas d'inventaires exhaustifs et précis des surfaces en prairies dans les zones agricoles, et ceci malgré l'augmentation importante au cours des dernières années du nombre de données de télédétection disponibles. Les prairies peuvent en effet être identifiées et localisées sur de grandes surfaces en utilisant des images satellites optiques à travers le calcul d'indices de végétation ou de variables biophysiques qui sont liés à l'état de la végétation tels que la densité, la hauteur de la végétation ou la biomasse [Xie *et al.* 2008, Jacquemoud *et al.* 2009, Rondeaux *et al.* 1996]. Ces indices et variables sont couramment utilisés pour suivre la croissance de la végétation et ainsi discriminer les différentes classes d'occupation des sols [Gao *et al.* 2013, Wei 2010]. Nous avons montré dans le chapitre précédent que le LAI est le paramètre le plus pertinent pour estimer la biomasse et décrire l'état de surface des prairies. Toutefois, l'intérêt de ce paramètre n'a pas encore été évalué pour différencier les prairies des cultures.

Cependant, dans certaines régions, l'acquisition d'images optiques pendant la saison végétative est limitée en raison de la présence de nuages et la capacité de revisite des capteurs. Par conséquent, les données radars, moins sensibles aux conditions climatiques que les données optiques, peuvent être considérées comme un complément idéal aux données optiques pour le suivi des prairies. De nombreuses études ont montré que les données radars sont bien corrélées avec des paramètres décrivant la végétation tels que la hauteur, la densité de la végétation ou la biomasse [Gao *et al.* 2013, McNairn & Brisco 2004, Baghdadi *et al.* 2009, Inoue *et al.* 2014, Bouman 1991, Le Toan *et al.* 1992].

Le but de ce chapitre est d'évaluer l'apport des séries temporelles d'images de télédétection à haute résolution spatiale optiques et/ou radars pour différencier les prairies des cultures. Dans un premier temps, trois séries temporelles de LAI dérivées d'images optiques à haute résolution spatiale acquises en 2006, 2010 et 2011 seront analysées. Puis, dans un second temps, plusieurs séries temporelles de paramètres dérivés de deux séries d'images radars acquises en 2010 et 2011 seront utilisées en complément des données optiques pour évaluer leur apport pour l'identification des prairies.



## 3.1. Analyse de séries temporelles d'images optiques à haute résolution spatiale pour l'identification des prairies

---

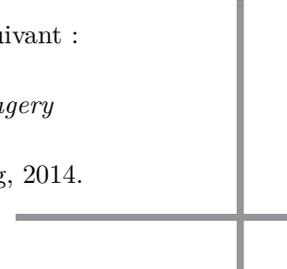
---

### CONTENTS

3.1.1	Introduction	103
3.1.2	Méthodologie	103
3.1.3	Résultats	104
3.1.3.1	Analyse des résultats de classification des séries temporelles	104
3.1.3.2	Quelles séries temporelles pour l'identification des prairies ?	107
3.1.4	Conclusion	110

---

**Abstract :** *The accelerating agricultural intensification has strongly reduced grassland surfaces in some areas, generating important changes in their management and affecting environmental and socio-economic systems. Therefore, the identification of grassland in farming systems is a key issue for sustainable agriculture. The main objective of this study is to identify grassland using time-series of optical satellite images at high/very high spatial resolution. For that purpose, we firstly applied the Support Vector Machine (SVM) classification technique to temporal profiles of Leaf Area Index (LAI) extracted from a series of remotely sensed images. Then, we searched to identify key-dates and evaluated the benefit of using temporal profiles to discriminate between grasslands and crops. Results we obtained show that while overall accuracy did not exceed 60% when only one satellite image is used for the classification, grasslands can be classified with an overall accuracy higher than 80% with four or five images per year. Besides, whereas results vary from one time series to another depending on image acquisition dates, this study also provides information on key-dates for image acquisition to improve grassland identification according to farming practices and phenology stages.*



Le contenu de cette partie a été soumis dans l'article suivant :  
**P. Dusseux**, T. Corpetti and L. Hubert-Moy.  
*Multi-temporal analysis of high spatial resolution imagery  
for grassland identification.*  
ISPRS Journal of Photogrammetry and Remote Sensing, 2014.

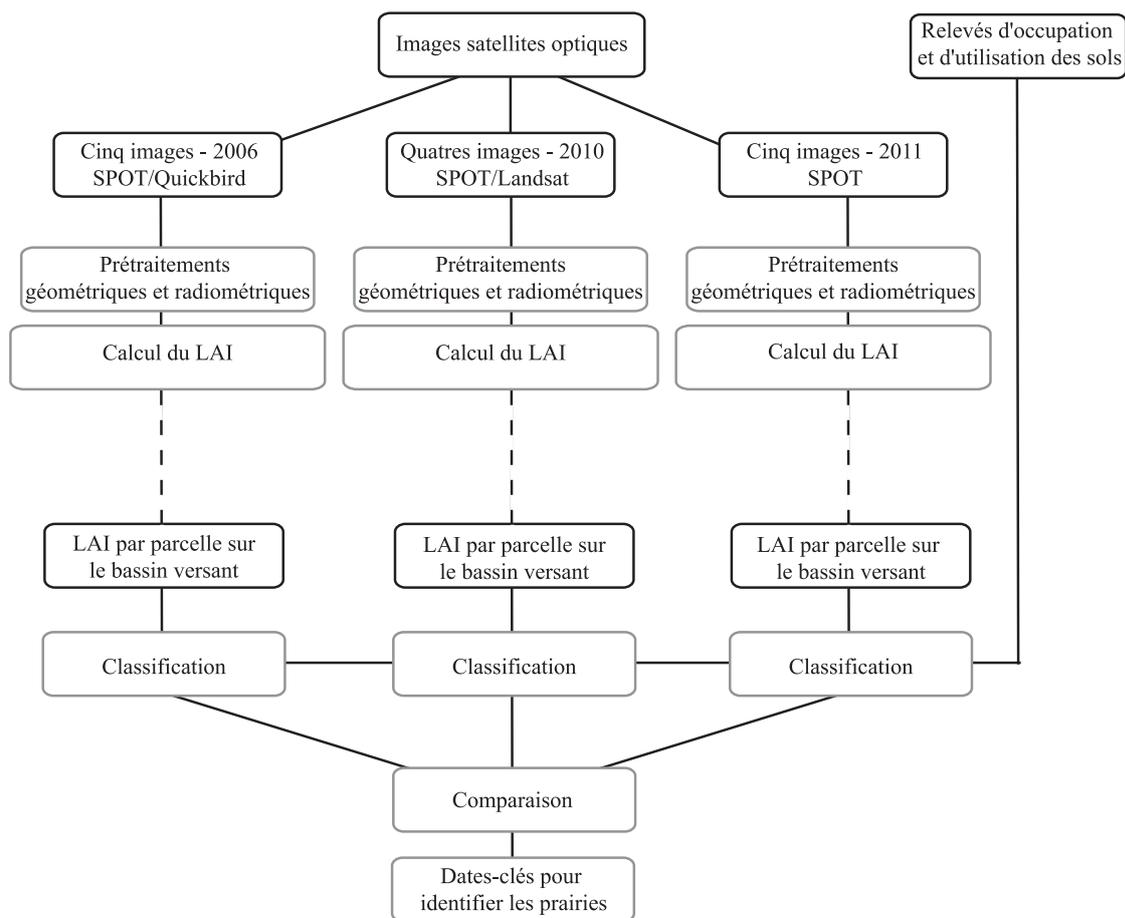


Figure 3.1 – Méthodologie générale appliquée à des séries temporelles d'images optiques à haute résolution spatiale pour identifier des prairies

### 3.1.1. Introduction

Cette partie porte sur l'évaluation de séries temporelles d'images optiques à haute résolution spatiale pour identifier les prairies.

Plus précisément, les objectifs de cette partie sont (1) de différencier les prairies des cultures en utilisant des séries temporelles d'images optiques à haute résolution spatiale et (2) de déterminer les dates-clés pour identifier les prairies.

Pour cela, les profils temporels de LAI dérivés de séries d'images satellites optiques à haute résolution spatiale ont été classés. Parmi les paramètres qu'il est possible de calculer à partir des données optiques, le LAI a été retenu car il a été identifié dans le chapitre précédent comme étant le paramètre le plus pertinent pour le suivi des prairies. Les profils temporels de LAI ont été classés en utilisant la technique du SVM qui est adaptée à la classification de séries temporelles d'images de télédétection. Au total, trois séries d'images constituées de données SPOT, Landsat et Quickbird acquises en 2006, 2010 et 2011 sur la zone d'étude ont été exploitées pour identifier les prairies (Figure 3.1).

### 3.1.2. Méthodologie

Trois séries d'images satellites optiques à haute résolution spatiale ont été utilisées pour identifier les prairies en 2006, 2010 et 2011 (Tableau 1.6, page 48). Ces séries sont composées d'images Quickbird, SPOT et Landsat acquises pendant la saison végétative des années concernées. Les relevés d'occupation des sols réalisés chaque mois sur le site d'étude ont été utilisés pour calibrer et valider les classifications des séries temporelles. Les images ont été pré-traitées et traitées selon le procédé décrit en section 1.4, page 47. Le LAI ayant été évalué comme étant le paramètre le plus pertinent pour l'étude des prairies, seul ce paramètre a été conservé. Les images de LAI, calculées à l'échelle du pixel ont été transformées à l'échelle de la parcelle pour palier le problème de la différence de résolution spatiale existant entre les images qui composent les séries (Section 1.4, page 47). Puis une classification de type SVM (Support Vector Machine) a été réalisée sur les profils temporels de LAI à l'échelle de la parcelle pour chaque année étudiée (Figure 3.2), les SVM ayant montré leur intérêt pour différencier des profils temporels proches (cf. section 1.4.1.4, page 53). L'indice de Kappa (K) a été calculé pour évaluer la précision des classifications.

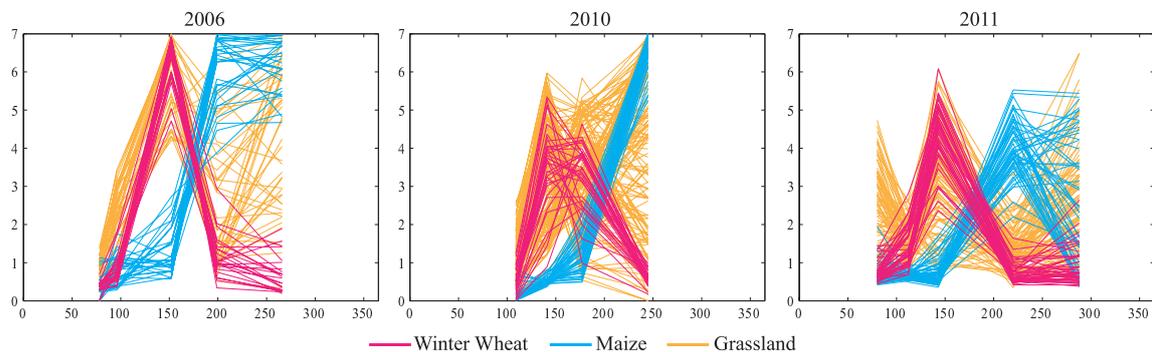


Figure 3.2 – Profils temporels de LAI correspondant aux échantillons terrain relevés pour les trois années étudiées (2006, 2010 et 2011)

### 3.1.3. Résultats

#### 3.1.3.1. Analyse des résultats de classification des séries temporelles

Le tableau 3.1 présente les matrices de confusion ainsi que la précision globale et le Kappa associé aux classifications. Comme on peut le voir la précision des classifications de l'occupation des sols est élevée, avec une précision globale de 94%, 88% et 84% et un indice de Kappa de 0.91, 0.81 et 0.83 pour 2006, 2010 et 2011, respectivement.

Tableau 3.1 – Matrice de confusion entre la classification réalisée à partir des séries temporelles (lignes) et les données de référence (colonnes) (%)

2006				
	Winter Wheat	Maize	Grassland	Over-detection
Winter Wheat	100	0	13	19
Maize	0	100	0	0
Grassland	0	0	87	0
Total	100	100	100	
Under-detection	0	0	13	
Kappa index = 0.91 and Overall accuracy = 0.94				
2010				
	Winter Wheat	Maize	Grassland	Over-detection
Winter Wheat	83	0	14	41
Maize	0	100	0	0
Grassland	17	0	86	4
Total	100	100	100	
Under-detection	17	0	14	
Kappa index = 0.81 and Overall accuracy = 0.88				
2011				
	Winter Wheat	Maize	Grassland	Over-detection
Winter Wheat	88	0	10	27
Maize	0	100	6	18
Grassland	12	0	84	17
Total	100	100	100	
Under-detection	12	0	16	
Kappa index = 0.83 and Overall accuracy = 0.90				

Les résultats de classification de l'occupation des sols obtenus avec les profils temporels de l'année 2006 montrent une sous-détection de 13% des prairies en faveur des céréales d'hiver (Tableau 3.1). Ces deux classes présentent des similitudes au cours de la saison de croissance de la végétation (Figure 3.2). En effet, les profils de LAI correspondant aux céréales d'hiver illustrent la période de croissance de la végétation entre avril et juin (DOY 96 et 152, respectivement) avec des valeurs de LAI supérieures à 4, puis la récolte pendant la période estivale (image de juillet, DOY 199) avec des valeurs

de LAI inférieures à 1. Les profils temporels correspondant aux parcelles de prairies montrent quant à eux plusieurs formes en fonction des pratiques agricoles réalisées sur les parcelles, certains profils ayant des formes très proches de ceux des céréales d'hiver. Nous pouvons par exemple observer des valeurs élevées de LAI au cours de la période de croissance des prairies (image de juin, DOY 152) alors qu'après cette période ces valeurs baissent plus ou moins fortement selon les modes de gestion des parcelles (image de juillet, DOY 199). Trois pratiques agricoles peuvent être identifiées au sein des prairies : le pâturage, la fauche et l'exploitation mixte. On observe une forte baisse des valeurs de LAI en juillet (DOY 199) pour les parcelles fauchées et une baisse modérée des valeurs de LAI pour les parcelles pâturées. En septembre (DOY 266), plusieurs configurations peuvent être observées : les valeurs de LAI sont faibles (inférieures à 3) quand les parcelles ont déjà été utilisées, tandis que les valeurs de LAI sont élevées (supérieures à 4) quand les parcelles n'ont pas encore été utilisées. En outre, les profils de LAI de maïs sont très différents de ceux des céréales d'hiver et des prairies. Les profils temporels de maïs montrent l'évolution des parcelles étant en sol nu puis progressivement couvert par la végétation depuis la période de semis jusqu'en juin (DOY 152), avant la période de croissance de la végétation jusqu'en septembre (DOY 266).

Les résultats de classification de l'occupation des sols obtenus avec les profils temporels de l'année 2010 montrent une sous-détection des céréales d'hiver et des prairies (17% et 14% respectivement) en faveur des prairies et des céréales d'hiver (Tableau 3.1). Comme cela a été observé précédemment pour les profils de l'année 2006, les céréales d'hiver et les prairies montrent des profils de croissance et des états de végétation similaires au cours de la saison végétative (Figure 3.2), ce qui a entraîné des erreurs de classification entre ces deux classes d'occupation des sols. Le maïs, quant à lui, est bien classé car l'évolution de la végétation dans ces parcelles est très différente des deux autres classes d'occupation des sols.

Les résultats de classification de l'occupation des sols obtenus avec les profils temporels de l'année 2011 montrent une sous-détection des céréales d'hiver (12%) en faveur des prairies. De plus, on observe une sous-détection des prairies en faveur des céréales d'hiver et des maïs (Tableau 3.1). Comme cela a déjà été observé avec les profils de 2006 et 2010, les céréales d'hiver et les prairies montrent des similitudes au cours de la période végétative, en particulier ici en mai et en août (DOY 143 et 222, respectivement) (Figure 3.2), ce qui explique les résultats observés.

Ainsi, les classifications réalisées à partir de séries temporelles d'images optiques sur les années 2006, 2010 et 2011 montrent de bons résultats pour discriminer les prairies des cultures. Cependant, il subsiste des erreurs, en particulier entre les céréales d'hiver et les prairies. Ceci s'explique par le fait que les pratiques agricoles effectuées sur ces parcelles sont proches, ce qui entraîne des états de surface similaires dans les parcelles à certaines périodes de la saison végétative comme le montrent les tableaux 3.2, 3.3 et 3.4 qui représentent les paramètres descriptifs (moyenne et variance) des profils temporels de LAI des classes d'occupation des sols pour 2006, 2010 et 2011. La variance montre à quel point un ensemble de profils temporels de la même classe d'occupation des sols est dispersé. Ainsi, les céréales d'hiver et les maïs ont une variance relativement faible alors que les prairies présentent une variance plus importante. En effet, selon les modes de gestion des prairies, les profils temporels peuvent être très différents d'une parcelle de prairie à une autre. Ainsi, en raison de cette variance intra-classe et en fonction des modes de gestion, les profils des prairies peuvent être similaires aux profils temporels des céréales d'hiver. Les LAI des parcelles de céréales d'hiver et de prairies estimés à partir des images satellites peuvent être très proches, notamment pendant la période de croissance de la végétation en mai et en juin dans l'Ouest de la France. Ainsi, il apparaît pertinent d'utiliser des séries temporelles d'images satellites qui ne se limitent pas à une ou deux images pour différencier les prairies des cultures.

Tableau 3.2 – Paramètres descriptifs (moyenne et variance) des profils temporels de LAI acquis en 2006

DOY		Winter Wheat	Maize	Grassland
78	Mean	0.4	0.4	0.8
	Variance	0.0	0.1	0.1
96	Mean	0.8	0.8	2.1
	Variance	0.1	0.1	0.6
152	Mean	6.3	1.3	5.9
	Variance	0.3	0.4	0.9
199	Mean	1.2	6.0	2.5
	Variance	0.3	0.8	<b>2.7</b>
266	Mean	0.7	6.2	4.1
	Variance	0.2	0.5	<b>3.4</b>

Tableau 3.3 – Paramètres descriptifs (moyenne et variance) des profils temporels de LAI acquis en 2010

DOY		Winter Wheat	Maize	Grassland
109	Mean	0.5	0.2	1.1
	Variance	0.1	0.1	0.3
141	Mean	<b>3.5</b>	0.6	<b>3.4</b>
	Variance	<b>1.2</b>	0.4	<b>2</b>
177	Mean	<b>3.3</b>	1.3	<b>3.2</b>
	Variance	0.8	0.5	<b>1.7</b>
145	Mean	0.8	6.4	3.9
	Variance	0.6	0.5	<b>4.5</b>

Tableau 3.4 – Paramètres descriptifs (moyenne et variance) des profils temporels de LAI acquis en 2011

DOY		Winter Wheat	Maize	Grassland
80	Mean	0.8	0.7	2.2
	Variance	0.2	0.1	<b>1.3</b>
112	Mean	1.5	0.6	1.6
	Variance	0.3	0.0	0.2
143	Mean	4.4	0.8	3.3
	Variance	0.6	0.1	<b>1.9</b>
222	Mean	0.7	4	1.3
	Variance	0.1	0.6	0.3
288	Mean	1.0	2.6	2.4
	Variance	0.6	3.3	<b>1.9</b>

### 3.1.3.2. Quelles séries temporelles pour l'identification des prairies ?

#### 3.1.3.2.1. Analyse des dates clés pour discriminer les prairies des cultures

Les classifications d'occupation des sols réalisées avec une seule image satellite (soit une information sur l'état de la végétation au cours de l'année) montrent une faible précision, le Kappa maximum atteignant 0.7 (Tableaux 3.5, 3.6 et 3.7). L'analyse de ces classifications permet néanmoins de faire ressortir les dates-clés permettant de discriminer les prairies des cultures :

Ainsi, au cours de l'année 2006, les résultats présentés dans le tableau 3.5 montrent un taux non négligeable de confusions entre les parcelles de prairies et de maïs au début de la période de croissance (mars et avril, DOY 78 et 96). En effet, une sous-détection des prairies en faveur du maïs (30% et 35%) et une sur-détection des prairies au détriment du maïs (17% et 4%) ont été observées respectivement avec les images de mars et avril. Cette période correspond au stade de développement des feuilles pour les parcelles de prairies tandis que le maïs n'est pas encore semé (sol nu). Ainsi, les valeurs de LAI estimées à partir des images satellites peuvent être similaires pour les parcelles de prairies et de maïs quand ces dernières sont partiellement couvertes par des repousses/résidus de végétation et que les parcelles de prairies ne sont pas couvertes à 100% par la végétation. Au stade de l'épiaison (image de juin, DOY 152), on observe une sur-détection des prairies (57%) au détriment des céréales d'hiver, cette période correspondant à un fort développement de la végétation pour ces deux classes. Ainsi, ces dernières ont des valeurs de LAI similaires. En outre, cette période est très importante pour distinguer les prairies des maïs. En effet, ces derniers étant justes semés, la couverture végétale est très faible et les valeurs de LAI correspondantes sont aussi très faibles. Pendant la période estivale (image de juillet, DOY 199), les parcelles de prairies ont des valeurs de LAI différentes en fonction des modes de gestion réalisés. Ainsi, des erreurs de classification peuvent être observées avec une sous-détection des prairies de 17% en faveur des maïs et une sur-détection des prairies de 57% au détriment des céréales d'hiver. En effet, cette période correspond au stade de l'épiaison pour les maïs (soit des valeurs élevées de LAI) et au stade de la sénescence pour les céréales d'hiver (correspondant à des valeurs faibles de LAI). Ainsi, selon les modes de gestion (pâturage, fauche), l'état de la végétation dans les parcelles de prairies peut être similaire à celui des cultures : d'une part, avant une fauche, la végétation des prairies peut être très dense ce qui se traduit par de fortes valeurs de LAI qui peuvent alors être confondues avec les valeurs de LAI correspondant aux parcelles de maïs. D'autre part, après un pâturage ou une fauche, la couverture végétale dans les parcelles de prairies est faible, ce qui se traduit par des valeurs de LAI faibles qui peuvent alors être confondues avec les valeurs de LAI correspondant aux parcelles de céréales d'hiver. À la fin de la période estivale (image de septembre, DOY 266), on observe une sous-détection des prairies (57%) en faveur des céréales d'hiver et du maïs et une sur-détection des prairies (4%) au détriment du maïs. Cette période correspond au stade de maturation du maïs (c'est-à-dire des valeurs élevées de LAI) et à la fin de la récolte pour les céréales d'hiver (c'est-à-dire des faibles valeurs de LAI). Ainsi, en fonction des modes de gestion des parcelles, les valeurs de LAI correspondantes peuvent être similaires à celles des cultures (si les valeurs de LAI sont élevées des confusions sont possible avec le maïs, si les valeurs de LAI sont faibles des confusions sont possible avec les céréales d'hiver).

L'analyse des résultats des classifications de 2010 et 2011 confirme les observations effectuées sur les séries temporelles de l'année 2006 (Tableaux 3.6 et 3.7) qui montrent deux périodes clés pour discriminer les prairies des cultures : (1) la période avril-juin, correspondant à la période de croissance des prairies et des céréales d'hiver alors que le maïs est tout juste semé et (2) la période août-septembre, correspondant à la période de récolte des céréales d'hiver, au stade de maturation du maïs et au stade de sénescence de la prairie.

Tableau 3.5 – Sous-détection, sur-détection et valeurs de Kappa pour les classifications de l'occupation des sols effectuées avec une seule date avec les données acquises en 2006

DOY		Winter Wheat	Maize	Grassland
78	Under-detection (%)	100	25	30
	Over-detection (%)	0	125	17
	Kappa Index	<b>0.28</b>		
96	Under-detection (%)	100	6	35
	Over-detection (%)	0	131	4
	Kappa Index	<b>0.35</b>		
152	Under-detection (%)	100	0	0
	Over-detection (%)	0	0	57
	Kappa Index	<b>0.58</b>		
199	Under-detection (%)	100	0	17
	Over-detection (%)	0	25	57
	Kappa Index	<b>0.46</b>		
266	Under-detection (%)	0	6	57
	Over-detection (%)	15	69	4
	Kappa Index	<b>0.60</b>		

Tableau 3.6 – Sous-détection, sur-détection et valeurs de Kappa pour les classifications de l'occupation des sols effectuées avec une seule date avec les données acquises en 2010

DOY		Winter Wheat	Maize	Grassland
109	Under-detection (%)	100	6	6
	Over-detection (%)	0	35	20
	Kappa Index	<b>0.58</b>		
141	Under-detection (%)	100	0	2
	Over-detection (%)	0	6	24
	Kappa Index	<b>0.64</b>		
177	Under-detection (%)	100	29	10
	Over-detection (%)	0	35	32
	Kappa Index	<b>0.40</b>		
245	Under-detection (%)	8	100	20
	Over-detection (%)	83	0	36
	Kappa Index	<b>0.28</b>		

Tableau 3.7 – Sous-détection, sur-détection et valeurs de Kappa pour les classifications de l'occupation des sols effectuées avec une seule date avec les données acquises en 2011

DOY		Winter Wheat	Maize	Grassland
80	Under-detection (%)	92	9	36
	Over-detection (%)	27	118	7
	Kappa Index	<b>0.37</b>		
112	Under-detection (%)	100	0	11
	Over-detection (%)	0	38	41
	Kappa Index	<b>0.53</b>		
143	Under-detection (%)	58	6	36
	Over-detection (%)	65	23	24
	Kappa Index	<b>0.48</b>		
222	Under-detection (%)	23	3	29
	Over-detection (%)	69	6	10
	Kappa Index	<b>0.67</b>		
288	Under-detection (%)	15	29	26
	Over-detection (%)	108	0	40
	Kappa Index	<b>0.27</b>		

### 3.1.3.2.2. Analyse du nombre d'images nécessaire pour discriminer les prairies des cultures

Les expériences précédentes montrent que les résultats de classification effectués avec une seule date pour discriminer les prairies des cultures sont assez mauvais. Dans cette section on constate cependant qu'il s'améliorent sensiblement avec l'utilisation de plusieurs images au cours de l'année. La figure 3.3 illustre, pour les années considérées (2006, 2010 et 2011), que l'utilisation du nombre maximum d'images satellites disponible permet de différencier les prairies des cultures avec un taux de précision supérieur à 0.8 (K), excepté pour l'année 2006. En effet, l'utilisation des cinq images disponibles en 2006 n'améliore pas les résultats de classification obtenus avec deux dates seulement (K=0.91). Ainsi, ces deux dates (images de juin et septembre, DOY 152 et 266, respectivement), qui peuvent être considérées comme des dates-clés, sont suffisantes pour discriminer les prairies des cultures. En effet, l'image de juin correspond au stade de l'épiaison pour les prairies et les céréales d'hiver (fortes valeurs de LAI) alors qu'à cette même période le maïs est tout juste semé (faibles valeurs de LAI). Ainsi, les valeurs de LAI des prairies et des céréales d'hiver estimées à partir des données satellites peuvent être similaires, mais elles sont très différentes de celles du maïs. L'image de septembre correspond au stade de maturation du maïs (fortes valeurs de LAI) et à la fin de la récolte des céréales d'hiver (très faibles valeurs de LAI). L'état des prairies dépend des modes de gestion réalisés sur les parcelles mais les valeurs de LAI estimées à partir des images sont supérieures à celles des parcelles de céréales d'hiver et généralement inférieures aux valeurs estimées sur les parcelles de maïs. La combinaison de ces deux dates permet donc de discriminer les prairies des cultures.

L'utilisation de séries temporelles intra-annuelles d'images satellites acquises par des capteurs tel que Sentinel-2 permettront d'améliorer l'identification et la caractérisation des prairies. En revanche, dans certaines régions, le nombre d'images satellites optiques disponibles reste limité pendant la saison végétative en raison d'une importante et fréquente couverture nuageuse. Ainsi, les données radars, insensibles aux conditions climatiques, peuvent être utilisées en complément des données optiques pour

identifier les prairies [Hill *et al.* 2005, McNairn *et al.* 2002]. Les données radars sont bien corrélées à l'état de la végétation et peuvent être utiles pour caractériser la rugosité de surface [Inoue *et al.* 2014, Buckley & Smith 2010, Smith & Buckley 2011, Hill *et al.* 2000]. Comme les céréales d'hiver et le maïs sont caractérisés par des structures et des hauteurs de végétation différentes comparativement aux prairies, il pourrait être plus aisé de les distinguer en utilisant des données radars en complément des données optiques.

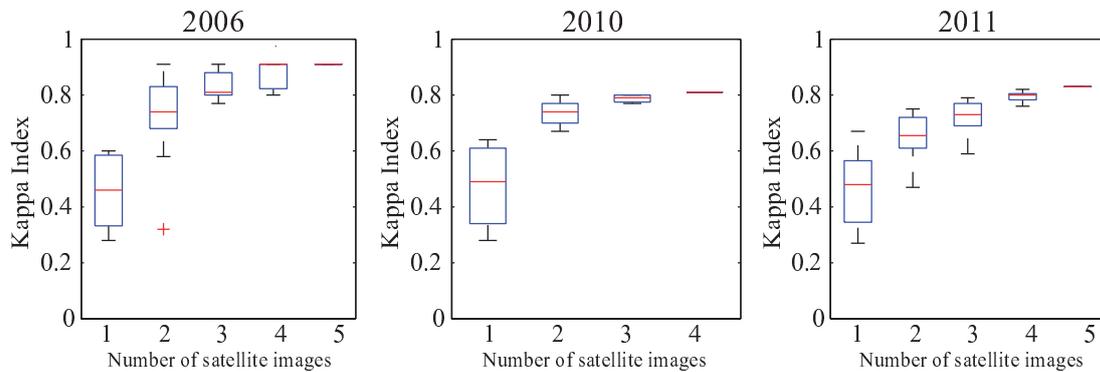


Figure 3.3 – Valeurs de Kappa obtenues en utilisant différentes combinaisons d'images satellites pour les séries acquises en 2006, 2010 et 2011

### 3.1.4. Conclusion

Dans cette partie, nous avons évalué la capacité de séries temporelles de LAI estimées à partir d'images satellites optiques à haute résolution spatiale pour discriminer les prairies des cultures. Les résultats de classification obtenus montrent que les prairies peuvent être identifiées avec une précision globale supérieure à 80% avec quatre ou cinq images par année. De plus, les résultats mettent en évidence que la précision globale des classifications ne dépasse pas 60% quand elles sont réalisées avec une seule image satellite. En outre, ils montrent que l'identification des prairies par rapport aux cultures peut varier en fonction de la série temporelle utilisée (nombre et dates d'acquisition des images satellites). Ainsi, nous avons mis en évidence, sur notre zone d'étude, les dates les plus adaptées à l'identification des prairies en fonction des pratiques agricoles et au développement phénologique des plantes.

## 3.2. L'apport de séries temporelles d'images radars pour l'identification des prairies

---

---

---

### CONTENTS

<b>3.2.1</b>	<b>Classification d'une série temporelle d'images optiques SPOT 5 et Landsat et d'une série temporelle d'images Radarsat-2 en mode « Quad-pol »</b>	<b>113</b>
3.2.1.1	Introduction	115
3.2.1.2	Méthodologie	115
3.2.1.3	Résultats	117
3.2.1.4	Conclusion	127
<b>3.2.2</b>	<b>Classification d'une série temporelle d'images optiques SPOT 4 et d'une série temporelle d'images Radarsat-2 en mode « Ultra-fin »</b>	<b>129</b>
3.2.2.1	Introduction	131
3.2.2.2	Méthodologie	131
3.2.2.3	Résultats	132
3.2.2.4	Conclusion	136

---



### 3.2.1. Classification d'une série temporelle d'images optiques SPOT 5 et Landsat et d'une série temporelle d'images Radarsat-2 en mode « Quad-pol »

---

#### CONTENTS

3.2.1.1	Introduction	115
3.2.1.2	Méthodologie	115
3.2.1.2.1	Les données	115
3.2.1.2.2	Analyse statistique	116
3.2.1.2.3	Classification	117
3.2.1.3	Résultats	117
3.2.1.3.1	Évaluation de la relation entre les coefficients de rétro-diffusion extraits des données radars et le LAI dérivé des données optiques	117
3.2.1.3.2	Analyse de l'évolution temporelle de paramètres utilisés pour l'identification des prairies	119
3.2.1.3.3	Analyse de la séparabilité entre les paramètres radars	123
3.2.1.3.4	Classification	124
3.2.1.4	Conclusion	127

---

**Abstract :** *The aim of this study was to assess the ability of optical images, SAR (Synthetic Aperture Radar) images, and the combination of both types of data to discriminate between grasslands and crops in agricultural areas where cloud cover is very high most of the time, which restricts the use of visible and near-infrared satellite data. We compared the performances of variables extracted from four optical and five SAR satellite images with high/very high spatial resolutions acquired during the growing season. A vegetation index, namely the NDVI (Normalized Difference Vegetation Index), and two biophysical variables, the LAI (Leaf Area Index) and the fCOVER (fraction of Vegetation Cover) were computed using optical time series and polarization (HH, VV, HV, VH). The polarization ratio and polarimetric decomposition (Freeman-Durden and Cloude-Pottier) were calculated using SAR time series. Then, variables derived from optical, SAR and both types of remotely sensed data were successively classified using the Support Vector Machine (SVM) technique. The results show that the classification accuracy of SAR variables is higher than those using optical data (0.98 compared to 0.81). They also highlight that the combination of optical and SAR time series data is of prime interest to discriminate grasslands from crops, allowing an improved classification accuracy.*

Le contenu de cette partie a été publié dans l'article suivant :  
**P. Dusseux**, T. Corpetti, L. Hubert-Moy and S. Corgne.  
*Combined use of multi-temporal optical and radar satellite images  
for grassland monitoring.*  
Remote Sensing, 6(7), 6163-6182, doi :10.3390/rs6076163, 2014.  
Annexe 2

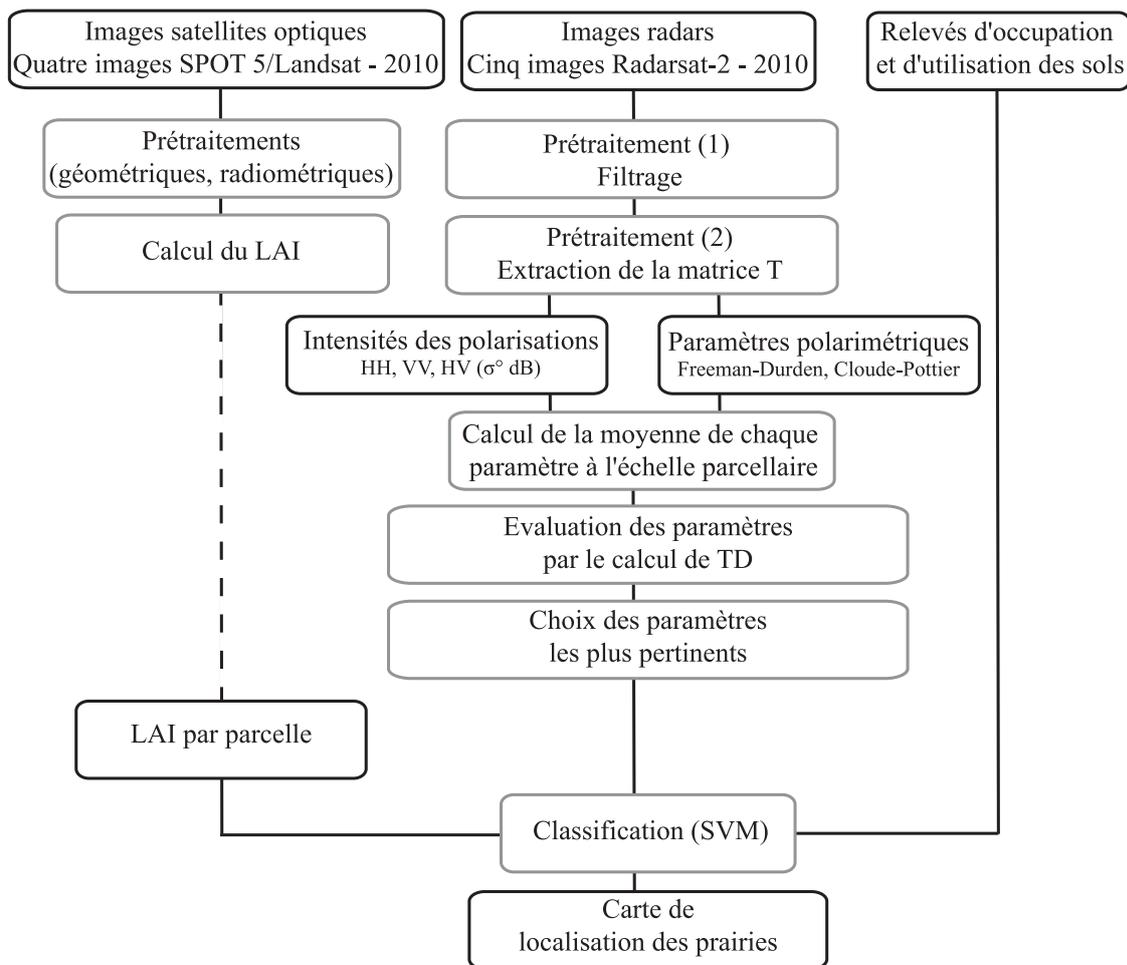


Figure 3.4 – Méthodologie générale appliquée pour identifier les prairies en utilisant de images optiques et radars

### 3.2.1.1. Introduction

Cette partie porte sur l'évaluation de séries temporelles à haute résolution spatiale d'images optiques, d'images radars et la combinaison des deux pour différencier les prairies des cultures. Nous avons montré dans la partie précédente que les séries temporelles d'images optiques permettent d'identifier les prairies avec une précision très élevée, les indices de Kappa variant de 0.88 à 0.94 en fonction des séries temporelles considérées. Les confusions qui subsistent entre les prairies et les cultures s'expliquent essentiellement par le fait que le nombre d'images constituant les séries n'est pas assez élevé ou que les dates d'acquisition des images ne sont pas optimales pour discriminer les couverts végétaux. La présence de la couverture nuageuse combinée à la faible capacité de revisite des capteurs optiques apparaissent comme des freins importants pour effectuer un suivi précis des prairies.

Les images radars, qui sont insensibles à la couverture nuageuse, offrent à cet égard une opportunité de compléter les séries d'images optiques. Toutefois, si des études ont montré que ces données sont bien corrélées avec des paramètres décrivant la végétation tels que la hauteur, la densité ou la biomasse, l'ensemble des paramètres qu'il est possible de dériver des données radars n'ont pas encore été évalués pour identifier les couverts prairiaux [Gao *et al.* 2013, McNairn & Brisco 2004].

L'objectif de cette partie est d'évaluer le potentiel des données optiques, des données radars et la combinaison des deux pour discriminer les prairies des cultures dans des zones agricoles où la couverture nuageuse est très importante la plupart du temps ce qui limite fortement l'utilisation des données satellites acquises dans les domaines du visible et du proche infrarouge. En particulier, nous allons chercher à évaluer l'apport des données Radarsat-2 acquises en mode « Quad-Pol » pour le suivi des prairies.

Pour cela, les profils temporels de LAI dérivés de séries d'images satellites optiques à haute résolution spatiale ont été classés. Parmi les paramètres qu'il est possible de calculer à partir des données optiques, le LAI a été retenu car il a été identifié dans le chapitre précédent comme étant le paramètre le plus pertinent pour le suivi des prairies. En parallèle, en ce qui concerne les données radars, les coefficients de rétrodiffusion acquis selon quatre polarisations, les ratios polarimétriques et les paramètres issus de deux décompositions polarimétriques ont été évalués et comparés. Puis, le LAI et les paramètres radars les plus pertinents ont été classés en utilisant la technique des SVM (Figure 3.4).

### 3.2.1.2. Méthodologie

#### 3.2.1.2.1. Les données

Une série de neuf images satellites à haute résolution spatiale a été utilisée pour identifier les prairies. Cette série est composée de quatre images optiques de type SPOT 5 et Landsat (Tableau 1.6, page 48) et de cinq images Radarsat-2 (Tableau 1.8, page 52) acquises pendant la saison végétative en 2010.

Les relevés d'occupation des sols réalisés chaque mois sur le site d'étude ont été utilisés pour calibrer et valider la classification des images satellites.

Le prétraitement des images optiques et radars a été détaillé dans la section 1.4 (page 47). Pour les images optiques, seul le LAI a été retenu parmi les paramètres dérivés de ces données car il a été considéré comme étant le paramètre le plus pertinent pour étudier des prairies (cf. chapitre 2). Concernant les données radars, le choix des paramètres retenus pour l'étude des prairies a nécessité les traitements suivants :

- Le calcul des coefficients de rétrodiffusion en  $\sigma^0$  (dB) et des ratios d'intensité (HH/VV, HH/HV et VV/HV) ;
- Le calcul de deux décompositions polarimétriques afin d'analyser les mécanismes de diffusion de la végétation : (1) la décomposition de Freeman–Durden [Freeman *et al.* 1994] avec trois mécanismes extraits : la diffusion de surface, la diffusion de volume et la diffusion à double réflexion et (2) la décomposition de Cloude–Pottier [Cloude & Pottier 1997] qui calcule les paramètres d'entropie ( $H$ ), l'angle alpha ( $\alpha$ ) et l'anisotropie ( $A$ ).

Ainsi, douze paramètres ont été extraits des images Radarsat–2. Ces paramètres, calculés à l'échelle du pixel, ont été structurés à l'échelle de la parcelle afin être comparé au LAI dérivé des données optiques (Section 1.4, page 47). Les analyses statistiques et les classifications ont été réalisées sur les profils temporels de LAI en ce qui concerne les données optiques (composés de quatre points - quatre dates d'images) et sur les profils de chacun des douze paramètres dérivés des images radars (cinq points - cinq images). Les résultats sont présentés dans la section suivante.

### 3.2.1.2.2. Analyse statistique

Les paramètres dérivés des données de télédétection varient dans des intervalles différents : par exemple le LAI varie entre 0 et 7 alors que le ratio d'intensité HH/VV varie de 0.5 à 1.3, etc. Ainsi, tous les paramètres ont été normalisés (données centrées-réduites) (Équation 2.2, page 80) afin de comparer les profils temporels extraits des images optiques et radars pour les trois classes d'occupation des sols.

Ensuite, on a calculé la mesure de la divergence transformée (TD) afin d'évaluer et de comparer la capacité des paramètres extraits des données optiques et radars pour discriminer les prairies des cultures.  $TD$  est un outil utilisé pour mesurer la séparabilité entre deux classes [Richards 2012, Brisco *et al.* 2011, Gambarova 2010, Hill & Foody 1994, Singh 1984]. La divergence ( $D_{ij}$ ) est d'abord calculée selon l'équation suivante :

$$D_{ij} = \frac{1}{2}Tr\{(cov_i - cov_j)(cov_j^{-1} - cov_i^{-1})\} + \frac{1}{2}Tr\{(cov_i^{-1} + cov_j^{-1})(\bar{x}_i - \bar{x}_j)(\bar{x}_i - \bar{x}_j)^t\} \quad (3.1)$$

où  $i$  et  $j$  représentent deux profils (de deux classes différentes) à comparer,  $cov_i$  est la matrice de covariance de la classe  $i$ ,  $\bar{x}_i$  est le profil moyen de la classe  $i$ ,  $Tr$  est la fonction trace et  $t$  est la fonction de transposition. À partir de  $D_{ij}$ , la divergence transformée  $TD$  est calculée par :

$$TD = 2(1 - \exp(\frac{-D_{ij}}{8})) \quad (3.2)$$

Les valeurs de  $TD$ , qui varient de 0 à 2, diminuent quand la distance entre les classes augmente. Selon la relation empirique entre  $TD$  et la probabilité de bonne classification établie dans [Swain & King 1973], les classes sont bien séparées si la valeur de  $TD$  est supérieure à 1.9, elles sont assez bien séparées si la valeur de  $TD$  est comprise entre 1.7 et 1.9 et les classes sont mal séparées si la valeur de  $TD$  est inférieure à 1.7.

### 3.2.1.2.3. Classification

Une fois les paramètres radars les plus discriminants sélectionnés en effectuant l'analyse de  $TD$ , ils ont été classés avec une technique SVM (Support Vector Machine) afin d'évaluer la capacité du LAI et des paramètres radars les plus discriminants à identifier les prairies des cultures. L'indice de Kappa ( $K$ ) a été utilisé pour évaluer la précision des classifications [Congalton 1991].

### 3.2.1.3. Résultats

#### 3.2.1.3.1. Évaluation de la relation entre les coefficients de rétrodiffusion extraits des données radars et le LAI dérivé des données optiques

La relation entre les paramètres dérivés des images radars et le LAI dérivé des images optiques a été évaluée en utilisant l'image optique acquise le 26 juin (DOY : 177) et l'image radar acquise le 15 juin (DOY : 166). Le mois de juin est le seul mois au cours duquel une image optique et une image radar ont été acquises avec des dates rapprochées (une dizaine de jours les sépare). Les diagrammes illustrant cette relation sont regroupés dans la figure 3.5.

L'analyse de ces diagrammes montre qu'il n'existe pas de relation linéaire entre le LAI et les paramètres radars. Toutefois, la combinaison du LAI avec un des six paramètres radars permet de distinguer les prairies des céréales d'hiver et du maïs. En effet, en considérant seulement une date, des confusions peuvent être observées si on utilise seulement le LAI ou seulement un des six paramètres radars, ces confusions étant dues notamment à un stade de croissance similaire des céréales et des prairies à cette période de l'année. Ainsi, les trois classes d'occupation du sol sont bien discriminées en particulier quand on considère le rapport d'intensité HH/VV avec la variable LAI (Figure 3.5). Le mois de juin correspond au début de la croissance de la végétation marqué par le développement des feuilles pour le maïs et à l'épiaison pour les céréales d'hiver et les prairies. Cependant ces dernières sont caractérisées par différents états de surface selon les modes de gestion mis en place sur les parcelles (pâturage, fauche). Ainsi, dans l'espace HH/VV - LAI, les céréales d'hiver ont des valeurs de HH/VV inférieures à celles des deux autres classes ( $< 0.8$ , atténuation du coefficient de rétrodiffusion en polarisation VV), alors que les valeurs de LAI sont similaires à celles de la classe des prairies. Le maïs montre des valeurs de HH/VV supérieures à celles des deux autres classes ( $> 0.9$ , signifiant que les coefficients de rétrodiffusion sont similaires pour les deux polarisations en raison de la contribution importante du sol nu), sauf pour quelques prairies qui ne sont pas couvertes totalement par la végétation. Le maïs se différencie des autres classes à travers la combinaison du ratio d'intensité HH/VV et du LAI, correspondant à de faibles valeurs de LAI ( $< 2$ ) et des fortes valeurs de HH/VV ( $> 0.9$ ). Les prairies se distinguent des céréales d'hiver par des valeurs de HH/VV globalement comprises entre 0.8 et 0.9, les céréales d'hiver correspondant à des valeurs situées entre 0.5 et 0.8. Enfin, les prairies se différencient du maïs avec (1) des valeurs de LAI et de HH/VV respectivement comprises entre 0 et 2 et entre 0.8 et 0.9 ou (2) des valeurs de LAI supérieures à 2 et des valeurs de HH/VV comprises entre 0.8 et 1 (les valeurs de LAI pour le maïs étant inférieures à 2 avec des valeurs de HH/VV supérieures à 0.9).

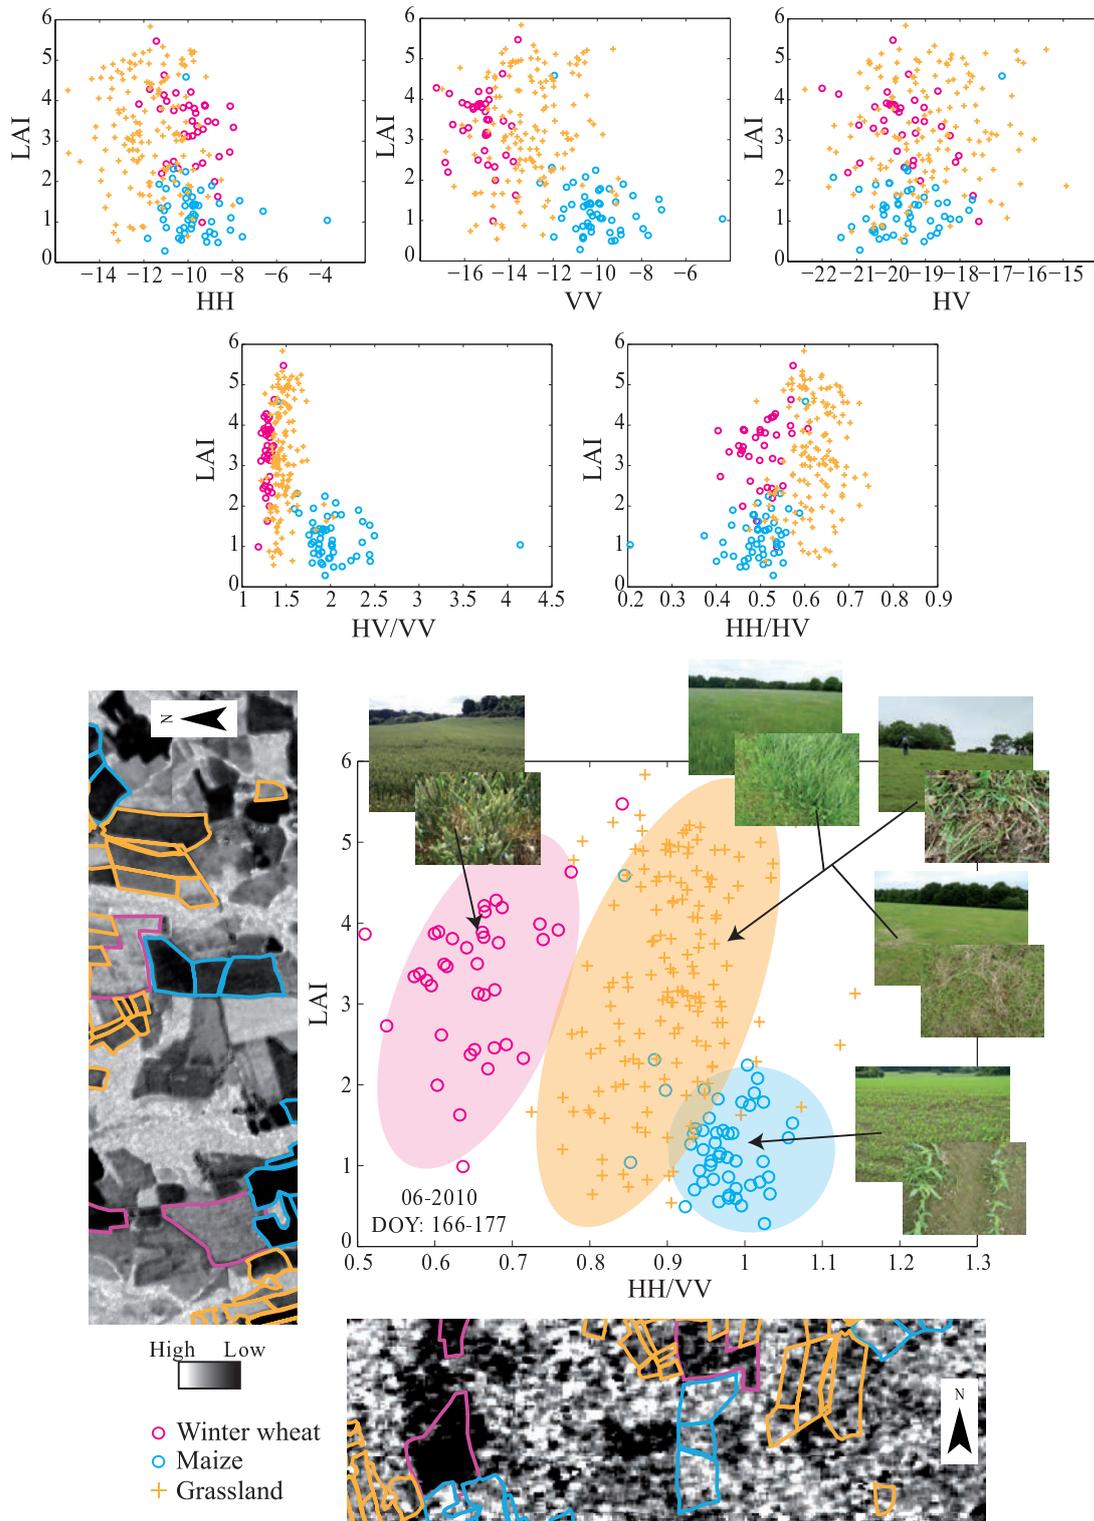


Figure 3.5 – Relation entre le LAI et les six paramètres dérivés des images radars pour les parcelles enquêtées en juin 2010

### 3.2.1.3.2. Analyse de l'évolution temporelle de paramètres utilisés pour l'identification des prairies

#### 3.2.1.3.2.1. Les paramètres LAI et HH/VV extraits des données optiques et radars

Les profils temporels de LAI extraits des données optiques et du ratio d'intensité HH/VV extraits des données radars correspondant aux trois classes d'occupation des sols sont représentés sur la figure 3.6. Le LAI apporte de l'information sur la croissance et l'état de la végétation, tandis que le rapport de polarisation HH/VV fournit des informations sur la structure de la végétation et donc indirectement sur les pratiques agricoles [Liu *et al.* 2013]. En effet, en bande C, le coefficient  $\sigma^0$  HH est généralement plus élevé que  $\sigma^0$  VV en raison de la forte atténuation de la rétrodiffusion en VV par les éléments verticaux (tiges) [Baghdadi *et al.* 2009, Ribbes 1999, Le Toan *et al.* 1997]. Les coefficients de rétrodiffusion sont donc fortement liés à la phénologie des cultures influençant les mécanismes de diffusion de la cible [Inoue *et al.* 2014, Baghdadi *et al.* 2009, McNairn & Brisco 2004]. Ainsi, de nombreuses études utilisent des séries temporelles de coefficients de rétrodiffusion et de ratios d'intensité pour le suivi de l'occupation et de l'utilisation des sols en contexte agricole [Betbeder *et al.* 2013, Koppe *et al.* 2013, Liu *et al.* 2013].

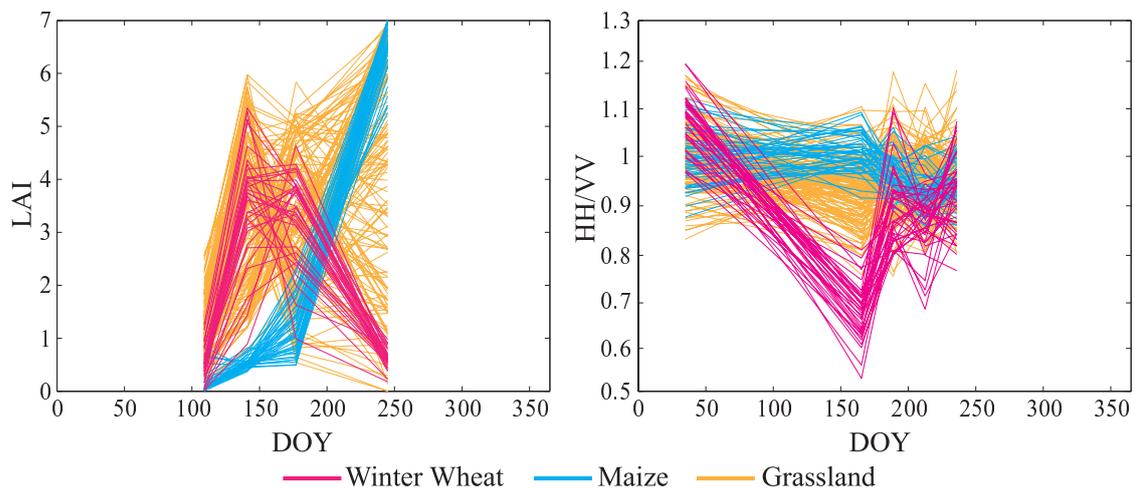


Figure 3.6 – Profils temporels de LAI et du rapport de polarisation HH/VV pour les parcelles enquêtées

Les trois classes d'occupation des sols à discriminer montrent des profils temporels différents en fonction du calendrier agricole (Figure 3.7), reflétant ainsi les pratiques agricoles :

- Les profils de LAI des céréales d'hiver illustrent d'abord la période de développement des feuilles jusqu'à la floraison (images de mai et juin, DOY 141 et 177 respectivement) avec des valeurs de LAI supérieures à 3, puis la récolte après le stade de sénescence à la fin de la période estivale (image de septembre, DOY 245) avec des valeurs de LAI inférieures à 1. Les profils du ratio d'intensité HH/VV montrent des valeurs proches de 1 au début du développement des feuilles (image de février, DOY 33), mettant en évidence de faibles variations de rétrodiffusion entre HH et VV qui sont dues au faible développement des céréales d'hiver à cette période (diffusion spéculaire). Au stade de floraison, au cours du printemps (image de juin, DOY 166), les valeurs de HH/VV sont comprises entre 0.5 et 0.8, illustrant une rugosité de surface importante due

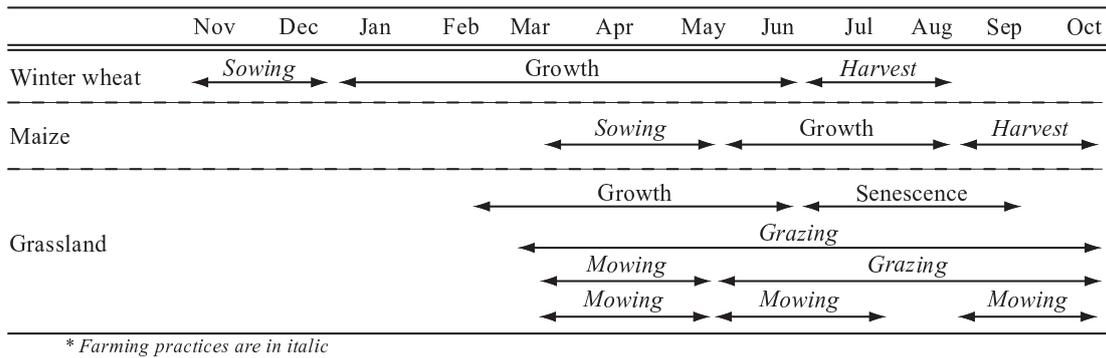


Figure 3.7 – Stades phénologiques et pratiques agricoles pour les trois classes d’occupation des sols étudiées

à la croissance des plantes (faibles valeurs de rétrodiffusion en VV). Au stade de la sénescence (image de juillet, DOY 190) la récolte des céréales d’hiver débute et les valeurs d’intensité du ratio HH/VV augmentent, en raison de la présence de sols nus (diffusion spéculaire). Après la récolte, des repousses peuvent être observées dans les parcelles de céréales d’hiver (images d’août, DOY 214 et 238). Celles-ci peuvent influencer le signal rétrodiffusé : on voit une diminution de HH/VV sur les parcelles ayant des repousses de végétation alors qu’une augmentation des valeurs du rapport HH/VV est observée pour les parcelles labourées.

- Les profils de LAI correspondant au maïs illustrent d’abord la période de sol nu puis de semis, avec des valeurs de LAI inférieures à 1 (images d’avril, de mai et juin, DOY 109, 141 et 177 respectivement). Ensuite, les profils montrent la période de croissance jusqu’à la maturation entre le début et la fin de la période estivale (images de juin et septembre, DOY 177 et 245 respectivement), les valeurs de LAI variant de 1 à 6. Les profils du ratio d’intensité HH/VV ont des valeurs hétérogènes pour l’image acquise en période hivernale (février, DOY 33). À cette période, comme le maïs n’a pas encore été semé (semis en avril), les parcelles sont encore en sol nu, en labour ou en inter-culture, ces pratiques étant associées à des mécanismes de diffusion très différents. Au moment du développement des feuilles (image de juin, DOY 166), les valeurs du rapport HH/VV sont proches de 1, mettant en évidence de faibles variations de rétrodiffusion entre HH et VV en raison du faible développement du maïs à cette période (diffusion spéculaire). Pendant la période estivale qui correspond aux stades allant de la montaison à la floraison (images de juillet et août, DOY 190, 214 et 238, respectivement), les valeurs de HH/VV diminuent. Comprises entre 0.8 et 1, elles illustrent la croissance de la végétation qui atténue le signal rétrodiffusé en VV (diffusion diffuse).
- Les profils de LAI des prairies montrent différentes formes selon le mode de gestion de ces dernières. Les valeurs de LAI augmentent au cours de la période de croissance de la végétation, en allant du développement des feuilles à la floraison (images d’avril, de mai et juin, DOY 109, 141 et 177, respectivement) avec des valeurs de LAI comprises entre 2 et 6. Après cette période de croissance, les valeurs de LAI varient plus ou moins fortement en fonction des pratiques agricoles réalisées sur les prairies. En effet, trois pratiques majeures sont observées : le pâturage, la fauche et l’exploitation mixte. Ainsi, une baisse forte et rapide des valeurs de LAI après l’épiaison (image de juin, DOY 177) illustre la pratique de la fauche, alors que le pâturage s’identifie par une diminution plus lente des valeurs de LAI. Les profils temporels du ratio d’intensité

HH/VV sont relativement homogènes au cours de la saison végétative. Compris entre 0.9 et 1.1, ils mettent en évidence de faibles variations de rétrodiffusion entre HH et VV (diffusion spéculaire). Ainsi, la variation des états de surface des prairies n'est pas assez importante pour modifier le signal rétrodiffusé.

Comme des similitudes peuvent s'observer entre les différentes classes d'occupation des sols à certaines périodes de la saison végétative, l'utilisation de séries temporelles permet de discriminer les différentes classes d'occupation des sols (Figure 3.6).

### 3.2.1.3.2.2. Paramètres polarimétriques entropie et alpha issus de la décomposition de Cloude–Pottier et extraits des données radars

Les valeurs entropie ( $H$ ) et alpha ( $\alpha$ ) extraites de la décomposition polarimétrique de Cloude–Pottier [Cloude & Pottier 1997] qui définit les mécanismes de diffusion dominants (volume, surface, multiple (=double)) des classes sont représentées pour les échantillons des trois classes d'occupation des sols sur la figure 3.8. Les valeurs du paramètre  $\alpha$  sont comprises entre  $0^\circ$  et  $90^\circ$ , allant de la diffusion de surface ( $\alpha = 0^\circ$ ) à la diffusion multiple ( $\alpha = 90^\circ$ ) en passant par la diffusion de volume ( $\alpha = 45^\circ$ ). Les valeurs de  $H$  sont comprises entre 0 et 1, avec des valeurs de 0 pour des surfaces où un seul mécanisme de diffusion joue et des valeurs de 1 pour des surfaces où plusieurs mécanismes de diffusion interviennent.

La figure 3.8 illustre la très bonne séparabilité existante entre les trois classes d'occupation des sols, en particulier en juin (DOY 166). Elle montre aussi qu'il est nécessaire d'utiliser des données multi-temporelles pour identifier ces classes car en fonction des dates d'acquisition, les céréales d'hiver et les maïs peuvent présenter des similarités et ne peuvent donc pas être discriminés en utilisant seulement ces dates. En effet, la variation temporelle des rétrodiffusions radars s'est avérée efficace pour le suivi de l'occupation des sols qui varie en fonction de la croissance de la végétation. Cependant, un effet de saturation du signal a été observé dans plusieurs études menées sur des cultures ayant une hauteur supérieure à 50cm comme la canne à sucre [Baghdadi *et al.* 2009] ou le riz [Lam-Dao *et al.* 2009]. Ainsi, ce phénomène de saturation peut être observé entre les céréales d'hiver et le maïs à partir du mois d'août, lorsque ces deux classes ont des valeurs similaires. La figure 3.8 illustre bien le fait qu'il est nécessaire d'utiliser des données temporelles pour la discrimination des classes d'occupation des sols.

L'analyse de la décomposition polarimétrique de Cloude–Pottier montre que les prairies ont des valeurs d'entropie très différentes des cultures durant toute la période végétative. En effet, les prairies ont des valeurs de  $H$  très faibles comprises entre 0 et 0.2 contre des valeurs comprises entre 0.6 et 0.9 pour les cultures. De plus, juin-juillet semble être la période la plus appropriée pour distinguer les céréales d'hiver et le maïs. En effet, d'après le schéma de la classification bi-dimensionnelle basée sur  $H$  et l'angle  $\alpha$  [Lee & Pottier 2009, Cloude & Pottier 1997], les céréales d'hiver ont des valeurs  $\alpha$  plus élevées que celles du maïs (de 30 à 45 contre 10 à 25, respectivement), ce qui indique une diffusion dominante de volume pour les céréales d'hiver (déjà au stade de maturation à cette période) et une diffusion dominante de surface pour le maïs où le sol nu est encore dominant (tout juste semé et au stade du développement des feuilles à cette période de l'année) [McNairn *et al.* 2009, Park & Moon 2007]. Ces deux classes sont caractérisées par une entropie moyenne. En ce qui concerne les prairies qui sont marquées par une très faible entropie, le mécanisme de surface est le mécanisme de diffusion dominant avec une très faible entropie. De plus, selon [Cloude & Pottier 1997], des valeurs d'entropie faibles ( $H < 0,5$ ) offrent moins de détails sur la classe.

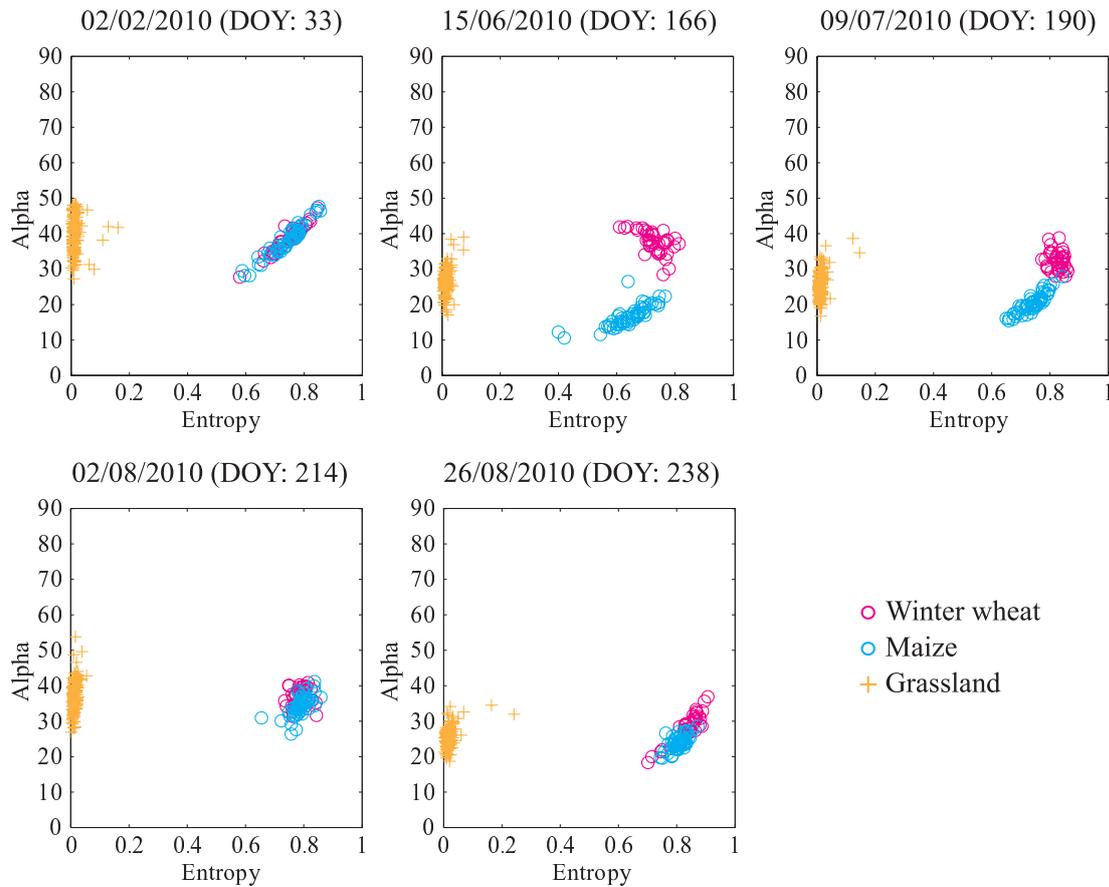


Figure 3.8 – Représentation des trois classes d’occupation des sols dans l’espace entropie ( $H$ ) et alpha ( $\alpha$ ), variables dérivées de la décomposition de Cloude–Pottier, pour chaque date d’acquisition

Ainsi, il apparaît que le radar peut être très utile pour distinguer les prairies des cultures.

### 3.2.1.3.2.3. Paramètres polarimétriques issus de la décomposition de Freeman–Durden et extraits des données radars

Les valeurs en volume, surface et double rebond extraites de la décomposition polarimétrique de Freeman–Durden [Freeman *et al.* 1994] sont représentées pour les échantillons des trois classes d’occupation des sols sur la figure 3.9.

Dans l’espace formé par les trois paramètres, on observe une assez bonne séparabilité entre les prairies et les cultures. En effet, les prairies montrent des valeurs en volume différentes de celles des cultures et ces valeurs varient en fonction des stades de développement de la végétation.

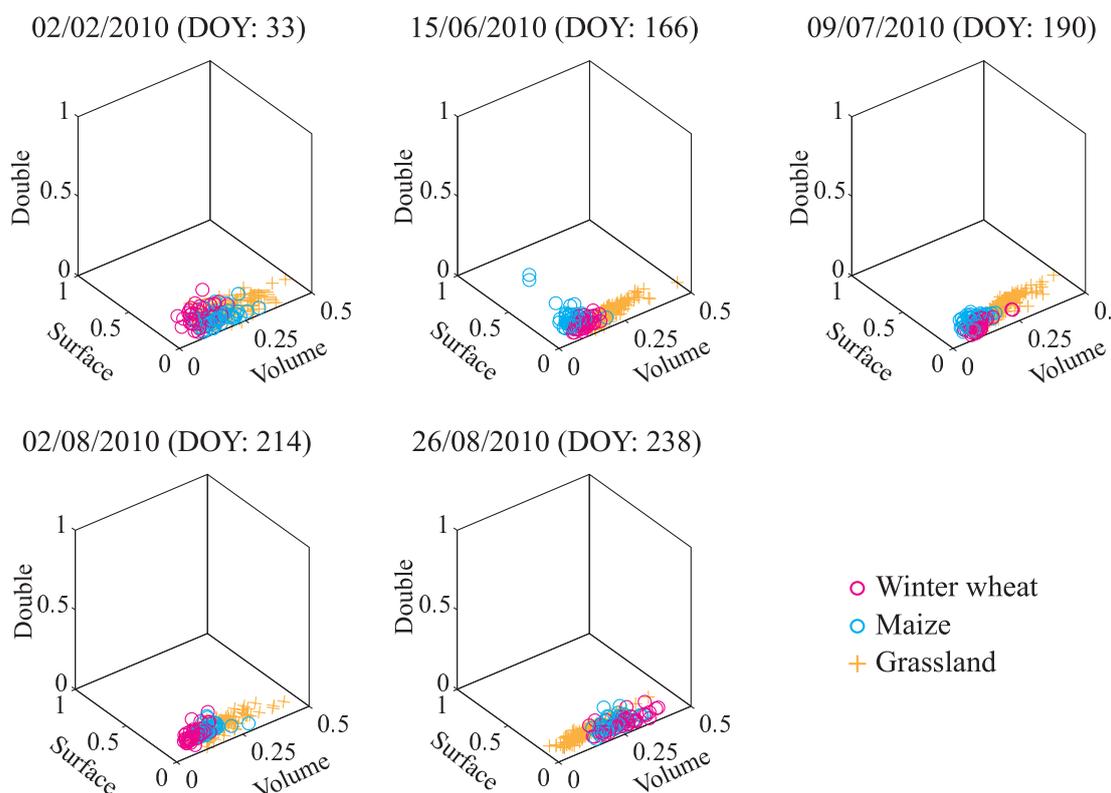


Figure 3.9 – Représentation 3D des trois classes d’occupation des sols dans l’espace comprenant les variables volume, surface et double rebond dérivées de la décomposition de Freeman–Durden pour les cinq date d’acquisition des images radars

### 3.2.1.3.3. Analyse de la séparabilité entre les paramètres radars

Les valeurs de divergence transformée ( $TD$ ) associées aux trois classes d’occupation des sols (céréales d’hiver, maïs et prairies) qui ont été calculées à partir des profils temporels des paramètres dérivés des images optiques et radars sont regroupées dans le tableau 3.8. Le LAI est la variable optique utilisée, les paramètres radars comprennent trois polarisations simples, une combinaison de polarisations, trois rapports de polarisation et deux décompositions polarimétriques. On peut observer que les valeurs de  $TD$  sont globalement très élevées ( $> 1.9$ ), ce qui indique que les classes d’occupation des sols ont une très bonne séparabilité. L’utilisation de données temporelles permet donc de suivre le développement de la végétation et de discriminer les prairies des cultures.

Parmi les paramètres radars, la combinaison des trois polarisations (HH, VV et HV) et les deux décompositions polarimétriques (Freeman–Durden et Cloude–Pottier) montrent des valeurs de  $TD$  égales à 2 pour distinguer les trois classes. Ceci concorde avec de nombreuses études qui ont montré l’intérêt des données polarimétriques pour le suivi de l’occupation des sols [Buckley & Smith 2010, Smith & Buckley 2011, Freeman *et al.* 1994]. De plus, des études ont montré que l’information polarimétrique des données radars sont corrélées avec l’état de la végétation [McNairn & Brisco 2004, Baghdadi *et al.* 2009, Inoue *et al.* 2014, Le Toan *et al.* 1992]. Ainsi, les classifications seront réalisées en utilisant la combinaison des trois polarisations et des deux décompositions polarimétriques.

Tableau 3.8 – Valeurs de la divergence transformée ( $TD$ ) obtenues entre les trois classes d'occupation des sols pour les paramètres LAI et radars

Variable set	Land cover		
	Winter wheat-Maize	Winter wheat-Grassland	Maize-Grassland
<b>Optical VARIABLE</b>			
LAI	2.00	1.99	2.00
<b>SAR VARIABLES</b>			
<b>Single polarization</b>			
$\sigma^{0HH}$	1.91	1.99	2.00
$\sigma^{0VV}$	1.95	2.00	1.98
$\sigma^{0HV}$	1.98	1.92	1.86
<b>Combination of polarizations</b>			
HH, VV, HV	2.00	2.00	2.00
<b>Polarization ratio</b>			
HH/VV	2.00	2.00	1.90
HH/HV	1.92	2.00	1.99
VV/HV	2.00	2.00	1.70
<b>Polarimetric decomposition</b>			
Freeman-Durden	2.00	2.00	2.00
Cloude-Pottier	2.00	2.00	2.00

#### 3.2.1.3.4. Classification

Le tableau 3.9 regroupe les matrices de confusion des classifications utilisant le LAI d'une part et les paramètres radars d'autre part.

Globalement, les trois classes d'occupation des sols sont bien discriminées : les classifications utilisant les paramètres des décompositions polarimétriques Freeman–Durden (Tableau 3.9-c) ou Cloude–Pottier (Tableau 3.9-d) présentent les meilleurs résultats avec des précisions globales ( $OA$ ) de 97% et 99% et des valeurs d'indice de Kappa ( $K$ ) de 0.95 et 0.98. On peut observer que des confusions subsistent entre les céréales d'hiver et le maïs alors que les prairies sont parfaitement identifiées. Ainsi, l'utilisation de séries temporelles de cinq images radars réparties durant la saison végétative permet d'identifier les prairies en milieu agricole. La classification utilisant la variable LAI (Tableau 3.9-a) montre une précision globale de 88% et un indice de Kappa de 0.81. Ici, les principales confusions sont observées entre les céréales d'hiver et les prairies (Figure 3.10), comme l'analyse des profils temporels de LAI effectuée précédemment l'a montré (Figures 3.6 et 3.7). En outre, seulement quatre images optiques ont pu être utilisées en raison d'une couverture nuageuse importante durant la saison végétative de 2010. Ainsi, certaines informations sur l'état de la végétation sont absentes de ces séries temporelles optiques. Enfin, la classification utilisant les trois polarisations (Tableau 3.9-b) montre une précision globale de 96% et un indice de Kappa de 0.87. En utilisant ces paramètres, des confusions peuvent être observées entre les trois classes d'occupation des sols : une sous-estimation de 17% des céréales d'hiver en faveur des prairies et une sur-estimation de 2% des maïs au dépend des prairies.

Tableau 3.9 – Matrices de confusion (en %) issues des classifications de l'occupation des sols utilisant la variable LAI dérivée des données optiques (a), la combinaison des polarisations HH, VV et HV, les paramètres issus de la décomposition de Freeman–Durden et les paramètres issus de la décomposition de Cloude–Pottier dérivés des données radars (b), (c) et (d), respectivement

(a)

	Winter wheat	Maize	Grassland	Total
Winter wheat	<b>83</b>	0	14	22
Maize	0	<b>100</b>	0	22
Grassland	17	0	<b>86</b>	56
Total	100	100	100	100

Overall accuracy = 88%, Kappa index = 0.81.

(b)

	Winter wheat	Maize	Grassland	Total
Winter wheat	<b>83</b>	0	0	13
Maize	0	<b>100</b>	2	23
Grassland	17	0	<b>98</b>	64
Total	100	100	100	100

Overall accuracy = 96%, Kappa index = 0.87.

(c)

	Winter wheat	Maize	Grassland	Total
Winter wheat	<b>83</b>	0	0	13
Maize	17	<b>100</b>	0	24
Grassland	0	0	<b>100</b>	63
Total	100	100	100	100

Overall accuracy = 97%, Kappa index = 0.95.

(d)

	Winter wheat	Maize	Grassland	Total
Winter wheat	<b>92</b>	0	0	14
Maize	8	<b>100</b>	0	23
Grassland	0	0	<b>100</b>	63
Total	100	100	100	100

Overall accuracy = 99%, Kappa index = 0.98.

Le tableau 3.10 présente les matrices de confusion des classifications utilisant la combinaison du LAI avec des paramètres radars. Les trois classes d'occupation des sols sont très bien distinguées (100% de précision) avec la combinaison du LAI et des paramètres issus de la décomposition polarimétrique Freeman–Durden (Tableau 3.10-b) d'une part, et avec la combinaison du LAI et des paramètres issus de la décomposition polarimétrique Cloude–Pottier d'autre part (Tableau 3.10-c). Ainsi, la combinaison de séries temporelles de LAI avec des séries temporelles de données radars polarimétriques permet d'éliminer complètement les confusions entre les cultures et par conséquent d'identifier les prairies [McNairn *et al.* 2009, McNairn & Brisco 2004].

Tableau 3.10 – Matrices de confusion (en %) issues des classifications de l'occupation des sols utilisant la combinaison des données optiques et radars : LAI - HH, VV et HV (a), LAI - les paramètres issus de la décomposition de Freeman–Durden (b) et LAI - les paramètres issus de la décomposition de Cloude–Pottier (c)

(a)

	Winter wheat	Maize	Grassland	Total
Winter wheat	<b>92</b>	0	2	15
Maize	0	<b>100</b>	0	22
Grassland	8	0	<b>98</b>	63
Total	100	100	100	100

Overall accuracy = 97%, Kappa index = 0.94.

(b)

	Winter wheat	Maize	Grassland	Total
Winter wheat	<b>100</b>	0	0	15
Maize	0	<b>100</b>	0	22
Grassland	0	0	<b>100</b>	63
Total	100	100	100	100

Overall accuracy = 100%, Kappa index = 1.

(c)

	Winter wheat	Maize	Grassland	Total
Winter wheat	<b>100</b>	0	0	15
Maize	0	<b>100</b>	0	22
Grassland	0	0	<b>100</b>	63
Total	100	100	100	100

Overall accuracy = 100%, Kappa index = 1.

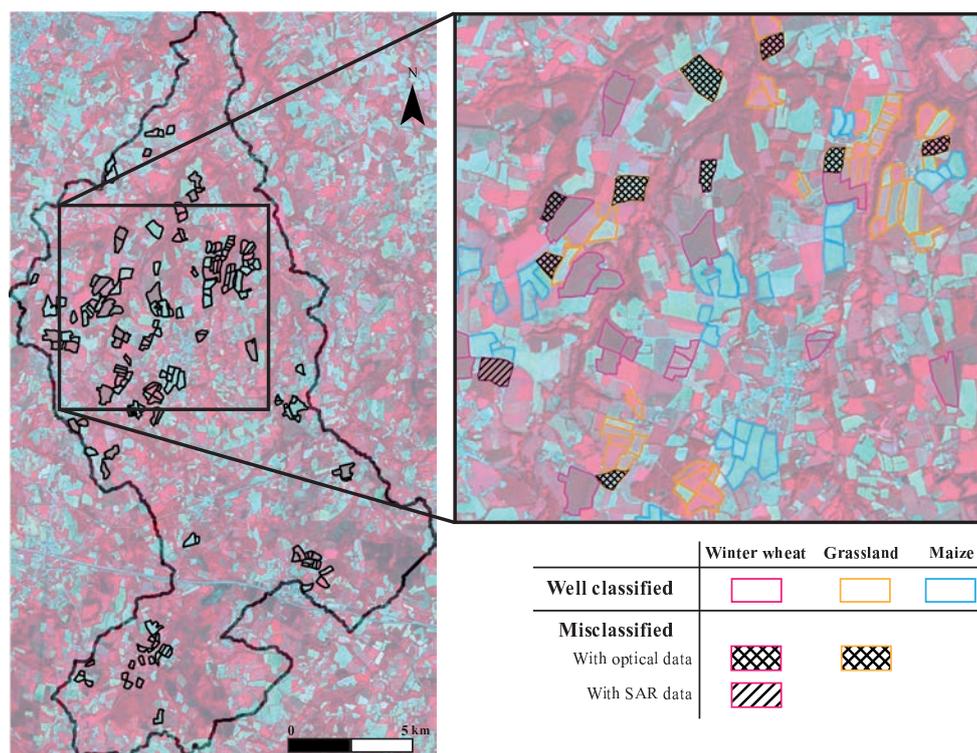


Figure 3.10 – Illustration des résultats de classification montrant les parcelles mal classées en utilisant exclusivement le LAI ou les paramètres issus de la décomposition de Cloude–Pottier et les parcelles bien classées en utilisant la combinaison du LAI et des paramètres issus de la décomposition de Cloude–Pottier

### 3.2.1.4. Conclusion

Dans cette partie, nous avons évalué la capacité de séries temporelles optiques et/ou radars à distinguer les prairies des cultures en zone agricole dans une région où la couverture nuageuse est importante au cours de l'année. Les résultats de classification ont montré que l'utilisation de cinq images radars bien réparties au cours de la saison végétative permet de discriminer les prairies des cultures avec une précision de 100%. Par ailleurs, la série temporelle de LAI dérivée des données optiques montre quelques confusions entre les prairies et les cultures, tandis que les séries des paramètres radars issus des décompositions de Freeman–Durden et Cloude–Pottier montrent des confusions limitées aux cultures. Cependant, la combinaison de la série temporelle de LAI dérivée des données optiques avec les séries temporelles de paramètres radars (que ce soit les paramètres issus des décompositions de Freeman–Durden ou Cloude–Pottier) permet d'éliminer toutes les confusions entre les prairies et les cultures d'une part et les confusions entre les cultures elles-même d'autre part ( $K = 1$ ).



### 3.2.2. Classification d'une série temporelle d'images optiques SPOT 4 et d'une série temporelle d'images Radarsat-2 en mode « Ultra-fin »

---

#### CONTENTS

3.2.2.1	Introduction	131
3.2.2.2	Méthodologie	131
3.2.2.2.1	Les données	131
3.2.2.2.2	Classification	132
3.2.2.3	Résultats	132
3.2.2.3.1	Évaluation de la relation entre le coefficient de rétro-diffusion VV dérivé des données Radarsat-2 et le LAI dérivé des données optiques SPOT	132
3.2.2.3.2	Analyse de l'évolution temporelle du LAI et du coefficient de rétrodiffusion VV	134
3.2.2.3.3	Analyse de la précision des classifications	135
3.2.2.4	Conclusion	136

---

Le contenu de cette partie sera intégré dans l'article suivant :

**P. Dusseux**, L. Hubert-Moy and S. Corgne.

*Investigating the relationship between C-band SAR data from Radarsat-2 satellite and LAI biophysical variable from SPOT satellite.*

Remote Sensing, soumission début 2015.

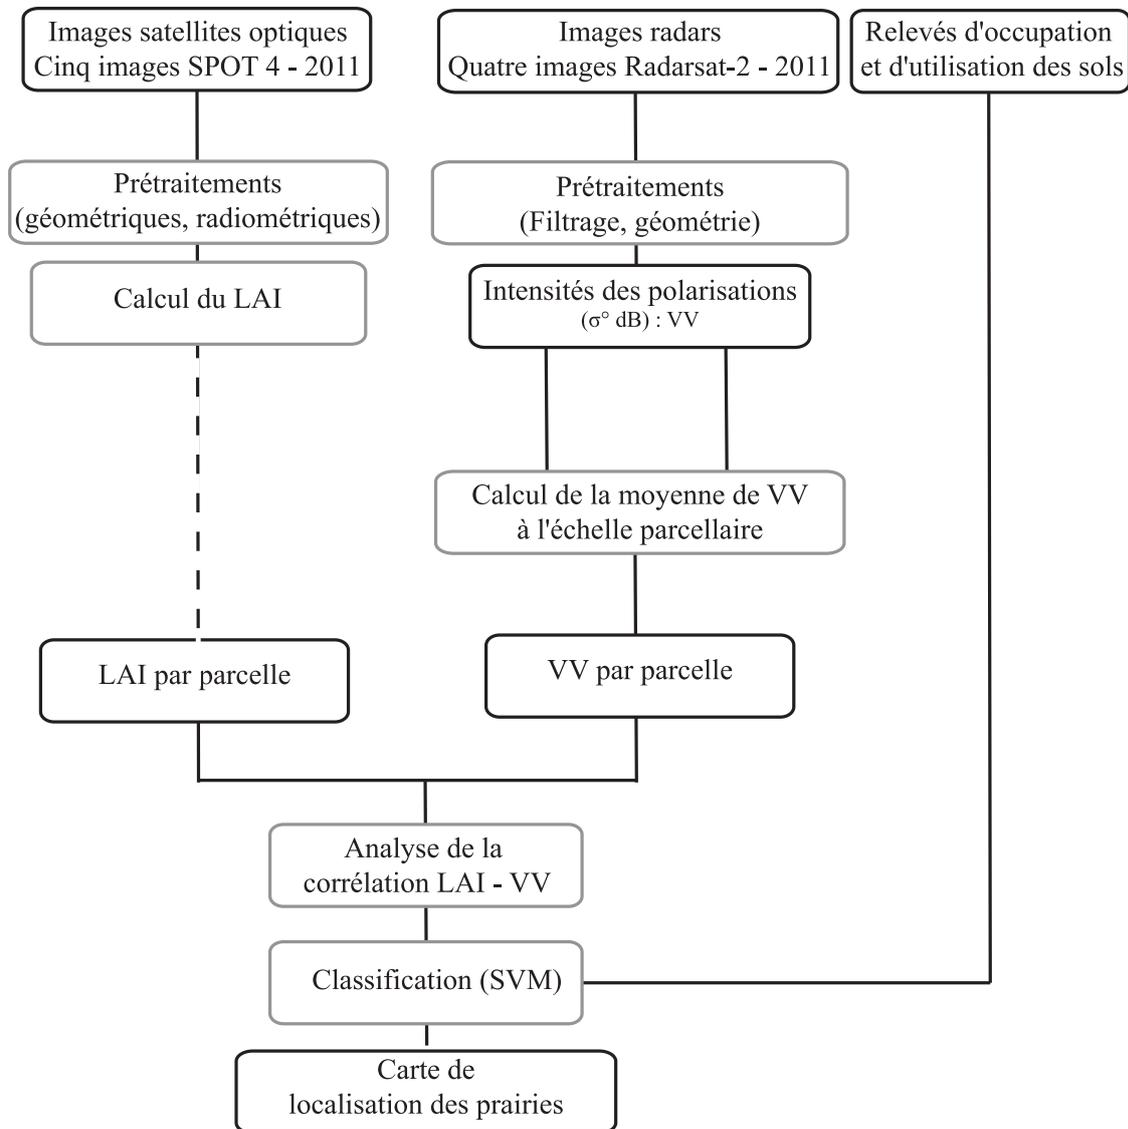


Figure 3.11 – Méthodologie générale appliquée pour identifier les prairies en utilisant des séries de données optiques et radars

### 3.2.2.1. Introduction

Comme la précédente, cette partie porte sur l'évaluation de séries temporelles à haute résolution spatiale d'images optiques, d'images radars et la combinaison des deux pour identifier les prairies des cultures. Alors que nous avons montré l'intérêt d'utiliser des images Radarsat-2 en mode « Quad pol » et leur synergie avec les données optiques, dans cette partie nous allons chercher à évaluer l'apport des données Radarsat-2 acquises en mode « Ultra-fin » et leur synergie avec les données optiques pour le suivi des prairies. En effet, les images Radarsat-2 en mode « Ultra-fin » qui possèdent la meilleure résolution spatiale disponible par télédétection radar en bande C (2m), apparaissent bien adaptées pour les études de suivi d'occupation des sols en paysage agricole fragmenté où la taille moyenne des parcelles est inférieure à 1ha. Il nous est donc apparu intéressant d'évaluer leur intérêt pour identifier les prairies.

Nous avons aussi montré dans les parties précédentes, d'une part que parmi les paramètres dérivés des données optiques le LAI est le plus pertinent pour identifier les prairies et d'autre part nous savons que la polarisation VV est très corrélée à la structure verticale de la végétation.

Toutefois, nous ne sommes par parvenu à établir une relation entre ces deux paramètres alors que la quantité de biomasse est liée à la hauteur de la végétation. Nous faisons l'hypothèse que cette absence de relation que nous avons observé dans la partie précédente était liée au décalage dans l'acquisition des dates des images radars et optiques et dans une moindre mesure à la plus faible résolution spatiale des données Radarsat-2 « Quad pol » (12m).

Ainsi, les objectifs de cette partie sont (1) de discriminer les prairies des cultures en utilisant des séries temporelles d'images optiques et/ou radars à haute résolution spatiale, les données radars étant acquises en mode « Ultra-fin » et (2) d'évaluer la relation entre le LAI issu des données optiques et le coefficient de rétrodiffusion VV issu des données radars (Figure 3.11).

### 3.2.2.2. Méthodologie

#### 3.2.2.2.1. Les données

Une série de neuf images satellites à haute résolution spatiale a été utilisée pour identifier les prairies. Cette série est composée de cinq images optiques SPOT 4 (Tableau 1.6, page 48) et de quatre images Radarsat-2 (Tableau 1.8, page 52) acquises pendant la saison végétative en 2011.

Les relevés d'occupation des sols réalisés chaque mois sur le site d'étude ont été utilisés pour calibrer et valider la classification des images satellites.

Les images ont été pré-traitées et traitées comme cela a été détaillé dans la section 1.4, page 47. Le LAI ayant été évalué comme le plus pertinent pour l'étude des prairies, seul ce paramètre a été conservé pour la série optique. Les images Radarsat-2 de cette série ont été acquises en mode « Ultra-fin » en polarisation VV, car cette polarisation est sensible aux éléments verticaux des surfaces ce qui permet *a priori* de différencier les prairies des cultures qui atteignent des hauteurs plus élevées au cours de la saison végétative.

Ainsi, la classification a été réalisée sur les profils temporels de LAI (composés de cinq points - cinq images) et sur les profils d'intensité radar en polarisation VV (composés de quatre points - quatre images).

### 3.2.2.2. Classification

Une classification de type SVM a été réalisée afin d'évaluer la capacité du LAI, du coefficient de rétrodiffusion VV et l'utilisation conjointe de ces deux paramètres pour l'identification des prairies. L'indice de Kappa (K) a été utilisé pour évaluer la précision des classifications.

### 3.2.2.3. Résultats

#### 3.2.2.3.1. Évaluation de la relation entre le coefficient de rétrodiffusion VV dérivé des données Radarsat-2 et le LAI dérivé des données optiques SPOT

La relation entre le coefficient de rétrodiffusion VV et le LAI a été évaluée pour les images acquises en mai et en août (Figure 3.12), puisque seulement 3 à 4 jours séparent l'image optique et l'image radar acquises au cours de ces deux mois.

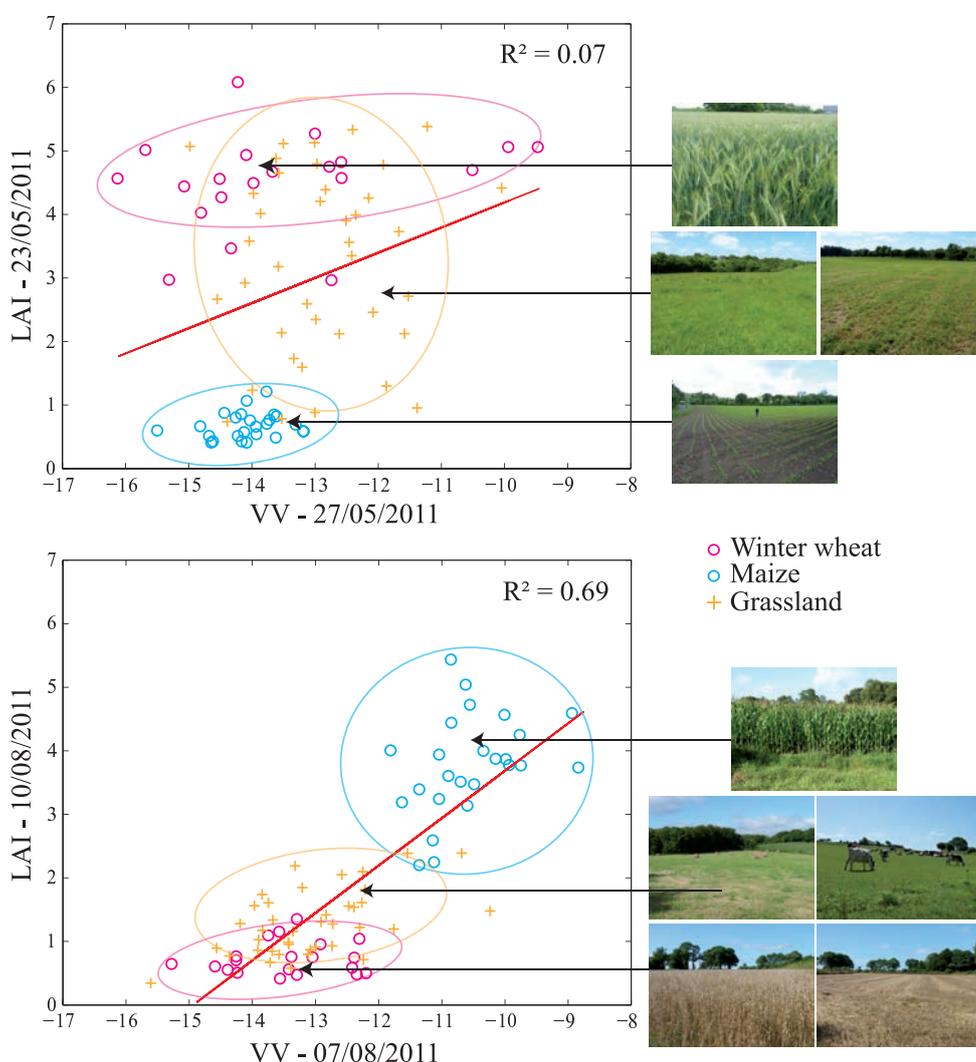


Figure 3.12 – Relation entre le LAI et le coefficient de rétrodiffusion VV pour les parcelles enquêtées en en mai et août 2011

Nous pouvons observer que la relation entre les paramètres dérivés des données optiques et ceux dérivés des données radars varient selon le stade phénologique de la végétation :

À la fin du mois de mai, période qui correspond au stade de développement de la végétation pour les prairies et les céréales d'hiver et au semis pour le maïs, aucune relation ne peut être établie entre le LAI et VV ( $R^2 = 0.07$ ). Alors que le LAI donne de l'information sur la densité de la végétation, la polarisation VV permet de décrire la structure des objets au sol. Ainsi, les céréales d'hiver et les prairies sont associées à des rétrodiffusions diffuses à la fin du mois de mai (Figure 3.12) puisque les feuilles ne sont pas encore totalement développées et que le sol peut encore être visible au sein des parcelles. De plus, les rétrodiffusions sont très hétérogènes au sein de la classe des céréales d'hiver, ceci pouvant être dû à l'interaction entre l'orientation des rangs et le signal (signal perpendiculaire ou parallèle au rang). En revanche, le maïs est associé à une rétrodiffusion spéculaire car comme il vient tout juste d'être semé, le sol nu est encore dominant (Figure 3.13).

En août, *a contrario*, la relation entre le LAI et le coefficient de rétrodiffusion VV est évidente : on observe de plus fortes rétrodiffusions pour le maïs que pour les céréales d'hiver et les prairies ( $R^2 = 0.69$ ), ce qui signifie que le couvert est dense et totalement couvrant (Figure 3.13). Concernant les parcelles de céréales d'hiver et de prairies, on observe en août comme en mai des rétrodiffusions diffuses qui sont dues à la sénescence et à la récolte des céréales et aux divers pratiques agricoles réalisées sur les prairies (végétation rase et sénescente avec un sol apparent). Ainsi, les images radars acquises à cette période de l'année permettent de décrire indirectement la densité de la végétation à travers un paramètre étant sensible au développement vertical de la végétation.

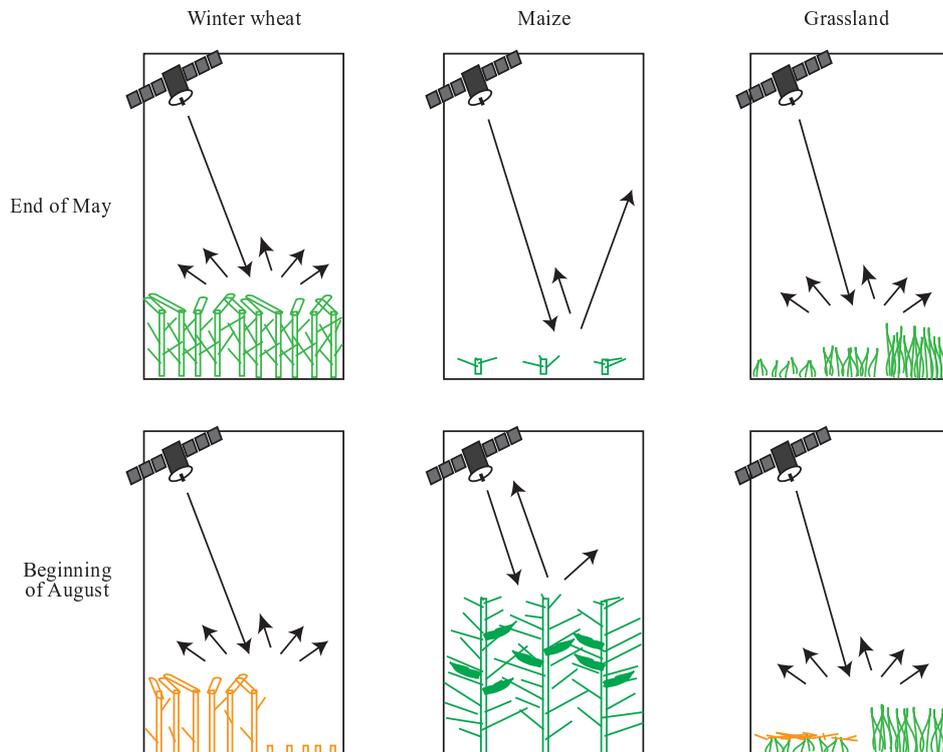


Figure 3.13 – Illustration des mécanismes de diffusion en fonction du stade phénologique de la végétation pour les trois classe étudiées

### 3.2.2.3.2. Analyse de l'évolution temporelle du LAI et du coefficient de rétro-diffusion VV

Les profils temporels de LAI et du coefficient de rétrodiffusion VV qui ont été élaborés à partir des parcelles échantillonnées pour les trois classes d'occupation des sols sont représentés sur la figure 3.14.

Les profils temporels correspondant aux trois classes d'occupation des sols diffèrent en fonction du calendrier agricole et des pratiques agricoles (Figure 3.7, page 120) :

- Les profils de LAI associés aux céréales d'hiver illustrent (1) le début du développement des feuilles, les valeurs de LAI étant comprises entre 1 et 2 sur l'image du mois d'avril (DOY 112), (2) le stade de floraison et de maturation à partir du mois de mai (DOY 143) avec des valeurs de LAI supérieures à 4 et (3) la période de récolte à la fin de la période estivale (image d'août, DOY 222) avec une baisse des valeurs de LAI qui deviennent à inférieures à 1. Les profils en polarisation VV illustrent le développement vertical de la végétation entre mai et juin (DOY 147 et 171 respectivement) avec une augmentation des valeurs de VV, puis la période de récolte à partir du mois d'août (DOY 219 et 243) avec une baisse des valeurs de VV.
- Les profils de LAI correspondant au maïs mettent en évidence (1) la période de sol nu/semis avec des valeurs de LAI inférieures à 1 (images de mars, avril et mai, DOY 80, 112 et 143, respectivement), (2) la période de croissance marqué par le développement des feuilles pendant la période estivale avec des valeurs de LAI supérieures à 4 (image d'août, DOY 222) et (3) la période de récolte à l'automne avec des valeurs de LAI inférieures à 2 pour les parcelles labourées et des valeurs de LAI comprises entre 3 et 4 pour les parcelles non labourées incluant parfois des repousses (image d'octobre, DOY 288). Les profils en polarisation VV illustrent la phase de croissance du maïs marquée par le développement des feuilles et des tiges (images de mai et juin, DOY 147 et 171, respectivement) engendrant une augmentation des valeurs de VV, puis la phase de maturation de la végétation (images d'août, DOY 219 et 243) génère des valeurs de VV stabilisées.
- Les profils de LAI associés des prairies sont plus complexes et hétérogènes selon les modes de gestion. Au début de la période de croissance de la végétation (image de mars, DOY 80) certaines parcelles ont déjà des LAI s'élevant 3 alors que d'autres parcelles (jeunes prairies, prairies dégradées, etc.) ont des LAI limités à 1. Ainsi, l'état des prairies diffère selon les pratiques agricoles effectuées en hiver. Ensuite, mi-mars marque le début du pâturage. On observe alors une baisse du LAI dans certaines parcelles qui ont commencé à être pâturées (image d'avril, DOY 112). La période de forte croissance de la végétation arrive au printemps (image de mai, DOY 143) et en fonction des modes de gestion on observe des valeurs de LAI hétérogènes : supérieures à 4 pour les parcelles encore non utilisées avec une végétation importante/dense, inférieures à 2 pour les parcelles pâturées ou fauchées de même pendant la période estivale (image d'août, DOY 222) et à l'automne (image d'octobre, DOY 288). *A contrario*, les profils temporels en polarisation VV sont relativement homogènes et stables au cours de la saison végétative avec des valeurs comprises entre  $-14$  et  $-12$ .

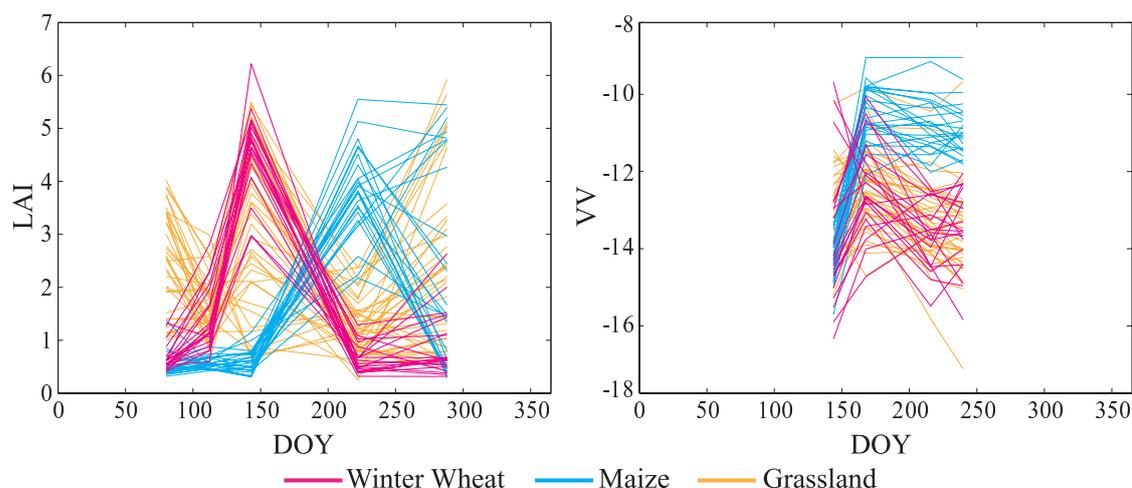


Figure 3.14 – Profils temporels de LAI et du coefficient de rétrodiffusion VV pour les parcelles enquêtées

### 3.2.2.3.3. Analyse de la précision des classifications

La classification basée sur les profils temporels de LAI montre une sous-estimation de 16% des prairies (10% en faveur des céréales d'hiver et 6% en faveur du maïs) (Tableau 3.11-a). Ce résultat est concordant avec les observations qui ont été effectuées avec les séries de LAI acquises en 2006 et en 2010 (Parties précédentes : 3.1 et 3.2.1).

La classification basée sur les profils temporels radars en polarisation VV montre une sous-estimation de 13% des prairies en faveur des céréales d'hiver (Tableau 3.11-b). Ces résultats concordent avec les observations qui ont été effectuées avec la série Radarsat-2 acquise en mode « Qual-pol » en 2010. On peut donc en conclure que la résolution spatiale supérieure de l'« Ultra-fin » ne compense pas l'absence de polarisations, en effet, les images acquises en mode « Qual-pol » permettent de dériver un nombre beaucoup plus important de paramètres dont certains permettent d'identifier précisément les prairies. Toutefois, l'exploitation des données acquises en mode « Qual-pol » requière un nombre de traitement important sans compter que le coût des images est plus élevé.

La classification basée sur la combinaison des profils temporels de LAI et VV montre une sous-estimation de 7% des prairies en faveur des céréales (Tableau 3.11-c). Ainsi, l'utilisation combinée de données temporelles optiques et radars permet de supprimer les confusions entre les prairies et le maïs. Toutefois, des confusions entre les prairies et les céréales d'hiver subsistent. En effet, ces deux classes montrent des profils temporels proches durant la période de croissance de la végétation (Figure 3.14). Ces résultats sont à comparer à ceux qui ont été obtenus avec les images acquises en mode « Qual-pol » en 2010 qui montraient que toutes les confusions entre les prairies et les cultures avaient été levées en exploitant la synergie optique-radar. En conséquence, on peut conclure que si l'exploitation de la synergie optique-radar permet d'améliorer sensiblement l'identification des prairies, l'utilisation des images radar en mode « Ultra-fin » ne permet pas de les identifier en totalité contrairement aux images acquises en mode « Qual-pol ».

Tableau 3.11 – Matrices de confusion (en %) correspondant aux classification de l'occupation des sols utilisant le LAI dérivé des données optiques (a), le coefficient de rétrodiffusion VV extrait des données radars (b) et la combinaison des paramètres LAI et VV (c)

(a)

	Winter Wheat	Maize	Grassland	Over-detection
Winter Wheat	<b>88</b>	0	10	23
Maize	0	<b>100</b>	6	11
Grassland	12	0	<b>84</b>	5
Total	100	100	100	
Under-detection	12	0	16	

Overall accuracy = 90%, Kappa index = 0.83.

(b)

	Winter Wheat	Maize	Grassland	Over-detection
Winter Wheat	<b>50</b>	0	13	41
Maize	0	<b>91</b>	0	0
Grassland	50	9	<b>87</b>	21
Total	100	100	100	
Under-detection	50	9	13	

Overall accuracy = 80%, Kappa index = 0.67.

(c)

	Winter Wheat	Maize	Grassland	Over-detection
Winter Wheat	<b>85</b>	0	7	19
Maize	0	<b>100</b>	0	0
Grassland	15	0	<b>93</b>	6
Total	100	100	100	
Under-detection	15	0	7	

Overall accuracy = 93%, Kappa index = 0.88.

### 3.2.2.4. Conclusion

Dans cette partie, nous avons évalué (1) la capacité de séries temporelles optiques et/ou radars à distinguer les prairies des cultures et (2) la relation entre le LAI dérivé d'images optiques et le coefficient de rétrodiffusion VV issu de données radars acquises en mode « Ultra-fin ». Les résultats confirment ceux qui ont été obtenus dans la partie précédente, en montrant l'intérêt de combiner une série optique et une série radar pour discriminer les prairies des cultures. Toutefois, la précision des classifications est moins élevée quand on utilise des données Radarsat-2 acquises en mode « Ultra-fin » qu'en mode « Quad-pol » car dans ce cas un seul coefficient de rétrodiffusion est disponible et la plus forte résolution spatiale des données acquises en mode « Ultra-fin » ne compense pas le plus faible nombre d'information disponible en termes de polarisations. Par ailleurs, les résultats ont permis de mettre en évidence que la relation entre des données optiques et des données radars est variable selon le stade de développement de la végétation et donc des dates d'acquisition des images. En effet, en fonction de la structure de la végétation, l'information issue des données radars sera, ou non, pertinente et complémentaire aux données optiques pour identifier les prairies.

## Synthèse et conclusion du troisième chapitre

---

Dans ce chapitre, nous avons cherché à évaluer l'apport des séries temporelles d'images de télédétection à haute résolution spatiale optiques et/ou radars pour différencier les prairies des cultures.

Des classifications ont d'abord été réalisées sur trois séries temporelles de LAI dérivées d'images satellites optiques acquises en 2006, 2010 et 2011. Les résultats obtenus montrent que les prairies peuvent être identifiées avec une précision globale supérieure à 80% avec quatre ou cinq images par an. Ils mettent aussi en évidence que la précision globale de la classification ne dépasse pas 60% quand une seule image satellite est utilisée. Ainsi, nous avons confirmé que la prise en compte de la dynamique des états de surface est très importante pour identifier les prairies. Nous avons aussi montré que les résultats peuvent varier d'une série temporelle à une autre en fonction des dates d'acquisition des images, ce qui nous a conduit à déterminer les dates optimales pour la discrimination des prairies en fonction des pratiques agricoles et des stades phénologiques des plantes.

Cependant, comme il est très difficile sur certaines zones d'acquérir plusieurs images optiques pendant la saison végétative en raison de la présence importante de nuages. Nous avons donc entrepris l'évaluation de données radars pour identifier les prairies.

Nous avons classé une série d'images Radarsat-2 acquise en mode « Quad-pol » en 2010 pendant la saison végétative. Plusieurs paramètres dérivés des données radars ont été testés, incluant les coefficients de rétrodiffusion, les paramètres issus de la décomposition de Cloude-Pottier et les paramètres issus de la décomposition de Freeman-Durden. La précision des classifications est très élevée, notamment quand on utilise des paramètres issus des deux décompositions polarimétriques. En effet, les prairies sont discriminées avec une précision globale de 100%, et ce, uniquement avec les paramètres radars. L'utilisation combinée de plusieurs paramètres radars et d'un paramètre optique (LAI) permet de discriminer avec une précision de 100% les prairies des cultures, en l'occurrence ici des céréales d'hiver et du maïs.

Nous avons également classé une autre série d'images radars, acquise cette fois en mode « Ultra-fin » pendant la saison végétative de 2011. Dans ce cas, le seul coefficient de rétrodiffusion disponible est le coefficient VV qui est sensible aux éléments verticaux. Les résultats obtenus montrent que la combinaison de cette série avec la série temporelle de LAI améliorent sensiblement la précision des classifications, l'indice de Kappa passant respectivement de 0.83 et 0.67 avec les seules données optiques et radars à 0.88 en utilisant la synergie optique-radar.

En outre, les résultats ont montré que la relation entre le LAI extrait des images optiques et le coefficient de rétrodiffusion VV issu des données radars varie selon le stade de développement de la végétation et en conséquence des dates d'acquisition des images. En effet, en fonction des stades phénologiques, l'information apportée par le radar peut, ou non, compléter l'information apportée par les images optiques sur l'état de la végétation (densité, hauteur, etc.).



# 4

## Exploitation de séries temporelles d'images satellites à haute résolution spatiale pour l'identification des modes de gestion des prairies

### Sommaire

---

<b>Introduction . . . . .</b>	<b>141</b>
<b>4.1 Comparaison de méthodes de classification pour identifier les modes de gestion des prairies . . . . .</b>	<b>143</b>
<b>4.2 Comparaison inter-annuelle de séries temporelles d'images optiques et/ou radars pour identifier les modes de gestion des prairies . . . . .</b>	<b>155</b>
<b>Synthèse et conclusion du quatrième chapitre . . . . .</b>	<b>165</b>

---



## Introduction

---

Les prairies jouent un rôle important tant sur le plan économique, pour la gestion des stocks de fourrages, que sur le plan environnemental, en influant notamment sur la régulation des flux d'azote et de polluants, et par conséquent sur la qualité de l'eau, des sols et de l'air [Lobell & Field 2007]. Cependant, le rôle fonctionnel des prairies varie avec les modes de gestion mis en place par les agriculteurs [Vertès *et al.* 2007]. Or, nous observons depuis plusieurs décennies des modifications des modes de gestion avec l'intensification de l'agriculture (surpâturage, augmentation du nombre annuel de fauches, fertilisation accrue, etc.). Dès lors, l'identification des pratiques agricoles réalisées sur les prairies représente un enjeu important.

L'identification des modes de gestion des prairies par télédétection requiert une forte répétitivité des observations, en raison de la diversité des pratiques agricoles associées aux prairies, de la fréquence de retour de ces pratiques sur les mêmes parcelles (2-3 fauches par an, pâturage tous les 30 jours), et du décalage temporel des pratiques d'une parcelle à l'autre. Étant donné que le nombre maximum d'images à haute résolution spatiale disponible dans le domaine optique est limité, nous serons amenés à exploiter des séries temporelles d'images radar. En effet, comme nous avons montré dans le chapitre précédent que la synergie optique-radar améliorerait la discrimination des prairies et des cultures, nous avons cherché à évaluer ces mêmes séries pour identifier les modes de gestion des prairies.

Nous avons montré l'intérêt d'un paramètre dérivé des images optiques, le LAI, pour identifier les prairies (Chapitre 3) et discriminer le pâturage de la fauche (Chapitre 2). En revanche, si certains paramètres radars se sont révélés adaptés à l'identification des prairies, leur capacité à distinguer les modes de gestion n'a pas encore été évaluée.

Nous avons montré qu'il était possible de classer des profils temporels de paramètres dérivés des données optiques et radars avec un bon, voire un très bon niveau de précision pour identifier les prairies en utilisant la technique du SVM. Toutefois, l'identification des modes de gestion au sein de la classe des prairies apparaît plus complexe que la différenciation des prairies et des cultures. En effet, la variabilité des pratiques agricoles effectuées sur les prairies entraîne une forte diversité des profils temporels des paramètres, qu'ils soient dérivés des images optiques ou radars. En outre, le faible nombre d'images au cours de la saison végétative entraîne un faible niveau de séparabilité entre les modes de gestion. Dans ce contexte de classification de séries temporelles complexes (hétérogènes, courtes, etc.) il est nécessaire d'envisager d'appliquer des méthodes adaptées à ce type de données.

L'objectif de ce chapitre est d'évaluer l'apport des séries temporelles d'images de télédétection à haute résolution spatiale optiques et/ou radars pour l'identification des modes de gestion des prairies, en l'occurrence ici : le pâturage, la fauche et l'exploitation mixte. La question de la classification des profils temporels de paramètres dérivés d'images satellites à haute résolution spatiale est traitée dans ce chapitre à travers la comparaison de plusieurs méthodes de classification.

Ces méthodes ont été appliquées dans un premier temps sur une série d'images optiques, puis dans un deuxième temps sur deux séries d'images optiques et deux séries d'images radars afin d'une part, d'évaluer la reproductibilité de ces méthodes de classification, et d'autre part, d'évaluer les images radars pour identifier les modes de gestion des prairies.



## 4.1. Comparaison de méthodes de classification pour identifier les modes de gestion des prairies

---

---

### CONTENTS

4.1.1	Introduction	145
4.1.2	Méthodologie	145
4.1.2.1	Les données	145
4.1.2.2	Classification de séries complexes basée sur des critères de déformation temporelle	146
4.1.3	Résultats	149
4.1.3.1	Analyse de l'évolution temporelle du LAI	149
4.1.3.1.1	Données simulées	149
4.1.3.1.2	Données réelles	150
4.1.3.2	Performances des méthodes de classification des séries temporelles	151
4.1.3.2.1	Résultats sur des données simulées	151
4.1.3.2.2	Résultats sur des données réelles	152
4.1.4	Conclusion	153

---

**Abstract :** *The main objective of this study is to identify grassland management practices using time series of remote sensing images. The accelerating agricultural intensification has strongly reduced grassland surfaces in some areas, generating important changes in their management and affecting environmental and socio-economic systems. Therefore, the identification of grassland management practices in farming systems is a key issue for sustainable agriculture. To this end, the Leaf Area Index (LAI) estimated from remote sensing images was used since its temporal evolution is informative about farming practices. We evaluate the performances of two common classification algorithms using time profiles of LAI derived from simulated data and High Spatial Resolution satellite images. We show that they exhibit limited performances, mainly because they rely on criteria that are not suited for the comparison of time series. We then suggest the use of more advanced classification tools that work in a transformed space designed by a kernel function. We show that a kernel based on time warping measurements, which are suited to the comparison of time series, perform better than classical ones based on Gaussian functions. This is a promising result in the perspective of analyzing the future SENTINEL data that will embed many time series.*

Le contenu de cette partie a été publié dans l'article suivant :  
**P. Dusseux, X. Gong, L. Hubert-Moy and T. Corpetti.**  
*Identification of grassland management practices from LAI time series.*  
Journal of Applied Remote Sensing, 8(1), 083559, 2014.  
doi :10.1117/1.JRS.8.083559

Annexe 3

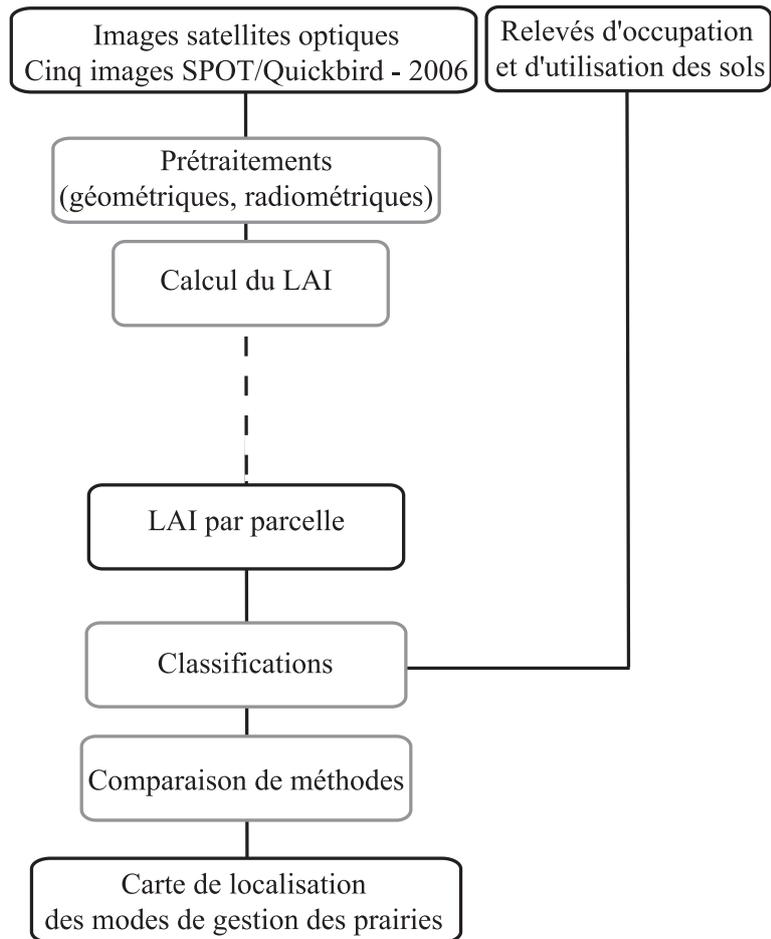


Figure 4.1 – Méthodologie générale appliquée pour comparer des méthodes de classification visant à identifier les modes de gestion des prairies

### 4.1.1. Introduction

Dans le contexte de la préparation des futures missions spatiales d'observation de la Terre telles que *Venùs* ou *Sentinel-2* et de la multiplication des satellites à haute résolution spatiale et temporelle, les méthodes de classification de séries temporelles d'images satellites optiques pour la caractérisation des prairies, en particulier pour identifier leurs modes de gestion, doivent faire l'objet d'une évaluation. Nous avons montré dans les parties précédentes que des séries temporelles d'images à haute résolution spatiale permettent de discriminer les prairies des cultures. Pour cela, des méthodes de classification assez simples ont été appliquées sur des séries de paramètres dérivés des images optiques et radars. En revanche, quand il s'agit d'identifier des modes de gestion au sein des prairies, la question de la classification des profils temporels de paramètres issus des données de télédétection devient plus difficile à résoudre en raison de la diversité des pratiques agricoles effectuées sur les prairies qui entraîne une très grande variété de profils temporels.

En conséquence, cette partie vise à (1) identifier les modes de gestion des prairies en utilisant une série temporelle d'images optiques à haute résolution spatiale et (2) évaluer plusieurs méthodes de classification appliquées à des séries temporelles complexes.

Pour cela, nous avons acquis une série de cinq images à haute résolution spatiale (de type SPOT et Quickbird) et les séries temporelles de LAI associées à chaque parcelle ont été classées pour identifier les trois modes de gestion des prairies (Figure 4.1).

La difficulté méthodologique de cette partie vient du fait que nous manipulons des séries temporelles très courtes (seulement quelques images pour une année) sur lesquelles nous cherchons à extraire une information riche (mode de gestion des prairies) où l'agencement temporel des valeurs de LAI joue un rôle primordial. Ainsi, une série ne peut être perçue comme un simple vecteur de données puisque les différentes valeurs de LAI associées à une parcelle sont corrélées entre elles et c'est précisément la nature de cette corrélation qui caractérise les classes que l'on cherche à extraire. Ainsi, les méthodes classiques de l'état de l'art qui ne prennent pas en considération ce lien temporel, ne sont pas optimales et il est nécessaire de se pencher sur des approches alternatives. Ce point sera abordé dans ce chapitre.

De plus, pour évaluer la performance des méthodes de classification testées pour cette étude, des profils temporels correspondant aux trois modes de gestion des prairies ont été simulés pour correspondre à des séries plus complètes qui pourront être acquises dans le cadre des futures missions spatiales d'observation de la Terre tel que *Venùs* et *Sentinel-2*.

### 4.1.2. Méthodologie

#### 4.1.2.1. Les données

Une série de cinq images satellites optiques à haute résolution spatiale a été utilisée pour identifier trois modes de gestion des prairies : le pâturage, la fauche et l'exploitation mixte. Cette série est composée d'une image Quickbird et de quatre images SPOT acquises pendant la saison végétative en 2006. Des relevés d'occupation et d'utilisation des sols, réalisés chaque mois sur le site d'étude, ont été utilisés pour calibrer et valider la classification des images satellites. Les traitements détaillés dans la section 1.4 (page 47) ont été appliqués aux images. Le LAI ayant été évalué comme étant le paramètre

le plus pertinent pour l'étude des prairies (Chapitre 2), seul ce paramètre a été retenu. Les images de LAI calculées à l'échelle du pixel ont été restructurées à l'échelle de la parcelle puisque les images de la série ont des résolutions spatiales différentes (Section 1.4, page 47).

Nous avons également utilisé des séries temporelles de LAI simulées afin d'évaluer les techniques de classification sur des séries temporelles d'images de télédétection comparables aux séries des futures données Sentinel-2. Ces séries ont été simulées à partir d'un modèle de croissance adapté aux prairies [Zhao 2014] dans lequel les divers modes de gestion (pâturage, fauche, mixte) ont été intégrés à différents intervalles de temps. Par ailleurs, un bruit blanc gaussien a été ajouté à ces données simulées afin de reproduire le plus fidèlement possible les artéfacts inclus dans les données réelles et générés par les techniques d'estimation des variables biophysiques. Chaque série est initialement composée de 365 valeurs (une par jour sur une année). Puis, 10% des points ont été supprimés de manière aléatoire afin de simuler des données manquantes à l'instar des séries temporelles d'images de télédétection réelles (images non utilisables en raison de la présence de nuages, d'aérosols, etc.).

En pratique, il n'est pas possible d'utiliser un critère de comparaison de séries basé sur une distance euclidienne (communément appelée la norme  $L_2$  qui est la norme classique entre deux vecteurs, équations 2.3, chapitre 2.2, page 77) lorsque les séries temporelles n'ont pas la même taille. Comme les séries que nous avons générées ont une taille variable, nous avons remplacé les valeurs manquantes en effectuant une interpolation linéaire entre les valeurs présentes dans les séries. En revanche, comme nous le verrons dans cette partie, nous utiliserons également des critères plus adaptés à la comparaison de séries temporelles (notamment la distance élastique DTW) qui ne requièrent pas d'avoir des séries de taille identique, ce qui est particulièrement adapté au cas des données manquantes. En pratique, nous avons utilisé un ensemble de 600 séries temporelles simulées de LAI (200 pour chaque classe). La moitié des séries simulées a été utilisée pour l'entraînement des classifications (100 pour chaque classe) et le reste a servi à la validation des classifications. Dans la section suivante, nous présentons les différents algorithmes de classification utilisés.

#### 4.1.2.2. Classification de séries complexes basée sur des critères de déformation temporelle

Les deux méthodes de classification utilisées sont la méthode des  $k$  plus proches voisins (KNN) et la méthode des séparateurs à vastes marges (SVM) (section 1.2.3, page 29).

Ces deux méthodes nécessitent le calcul d'une mesure permettant de comparer les séries temporelles. La norme Euclidienne  $L_2$  est la plus couramment utilisée pour comparer deux séries  $\mathbf{t}_1 = [t_{1,1}, \dots, t_{1,n}]^T$  et  $\mathbf{t}_2 = [t_{2,1}, \dots, t_{2,n}]^T : \|\mathbf{t}_1 - \mathbf{t}_2\| = \sqrt{\sum_{i=1}^n (t_{1,i} - t_{2,i})^2}$ . Cependant, cette mesure n'est pas toujours adaptée à la comparaison de séries temporelles complexes car les relations entre deux valeurs successives sont négligées et cela peut conduire à des écarts similaires en comparant des motifs totalement différents. Par exemple, sur la figure 4.2, la différence au sens de la norme  $L_2$  entre la courbe  $f$  (en bleu) et  $g$  (en noir) est identique à celle entre  $f$  et  $h$  (en rouge) alors qu'il apparaît évident que les courbes  $f$  et  $h$  sont de nature différente ( $h$  est similaire à  $f$  mais décalée dans le temps tandis que  $g$  n'a rien à voir). Malheureusement le critère  $L_2$  est incapable de mettre cela en évidence.

Ainsi, un noyau Gaussien tel que celui qui est utilisé dans les techniques SVM se comporte de manière similaire en comparant deux séries  $(\mathbf{t}_1, \mathbf{t}_2)$  ou tout couple de séries  $(\eta(\mathbf{t}_1), \eta(\mathbf{t}_2))$ ,  $\eta$  étant une fonction de permutation quelconque appliquée à  $\mathbf{t}_1$  et  $\mathbf{t}_2$ .

Ce manque de sensibilité fait du noyau Gaussien un noyau peu adapté à la classification de séries temporelles complexes. Il apparaît donc plus intéressant de s'appuyer sur des critères dédiés à la comparaison de séries et en particulier sur des critères cherchant à établir une correspondance (ou un *warping* en anglais) entre une série  $\mathbf{t}_1$  et une série  $\mathbf{t}_2$ . En pratique, pour mettre en correspondance

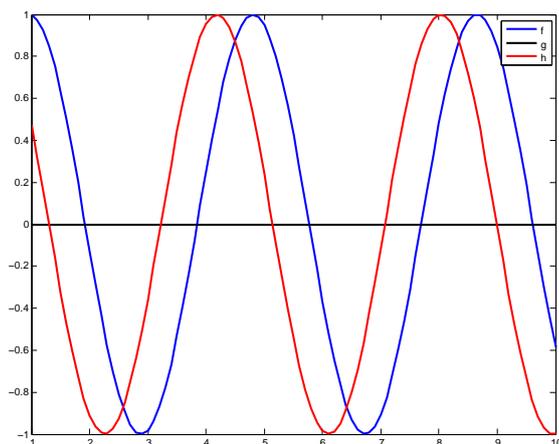


Figure 4.2 – Illustration de la difficulté d'utiliser la norme euclidienne. Sur cette figure, la distance (au sens de la norme  $L_2$ ) entre  $f$  et  $g$  est identique à celle entre  $f$  et  $h$  bien que les différences soient de nature différentes (dans un cas on a des courbes qui n'ont rien à voir, dans l'autre on a simplement un décalage temporel)

ces séries, on calcule dans un premier temps une matrice de pénalisation  $P$  de taille  $m \times n$  où chaque élément  $P(i, j)$  représente le coût pour passer de  $t_{1,i}$  à  $t_{2,j}$ . Cette matrice se calcule par :

$$P(i, j) = |t_{1,i} - t_{2,j}|. \quad (4.1)$$

Un chemin de déformation (ou *warping path* en anglais)  $W = w_1, \dots, w_K, K \in [\max(m, n), m+n-1]$  est l'ensemble des coordonnées dans la matrice  $P$  qui permettent de passer de  $P(1, 1)$  à  $P(m, n)$ , tout en respectant les contraintes suivantes :

- $w_1 = (1, 1)$  et  $w_K = (m, n)$  (points de départ et d'arrivée) ;
- $w_{i+1}$  est à côté de  $w_i$  pour tout  $i \in [1, K-1]$  (continuité du chemin) ;
- $(w_{i+1} - w_i)(w_i - w_{i-1}) > 0$  pour  $i \in [2, K-1]$  (contrainte de monotonie : on ne fait pas chemin inverse).

Sur la base de la matrice  $P$  et des différents chemins  $w$  possibles, un certain nombre de critères de déformation temporelle peut être calculé. Le plus connu, nommé DTW pour *Dynamic Time Warping*, s'appuie sur l'extraction du chemin à coût minimal pour passer de la série  $\mathbf{t}_1$  à  $\mathbf{t}_2$ . Plus précisément, le critère  $D_{dtw}(\mathbf{t}_1, \mathbf{t}_2)$  est issu du chemin qui possède la plus petite somme normalisée des pénalités associées dans la matrice  $P$  :

$$D_{dtw}(\mathbf{t}_1, \mathbf{t}_2) = \min \frac{\sum_{k=1}^K P(w_k)}{K}. \quad (4.2)$$

Ce critère a été utilisé dans de nombreuses disciplines (notamment pour le traitement de la parole et de la reconnaissance de sons) pour comparer des motifs temporels. Des implémentations très efficaces pour rechercher le chemin optimal dans la matrice  $P$  existent (en s'appuyant sur des techniques de *programmation dynamique*), ce qui fait que ce critère est très populaire. En pratique, une matrice de distance  $D$  de taille  $m \times n$  est calculée avec  $D(1, 1) = P(1, 1)$  et :

$$D(i, j) = \min \begin{cases} D(i-1, j) + P(i-1, j) \\ D(i-1, j-1) + P(i-1, j-1) \\ D(i, j-1) + P(i, j-1) \end{cases}. \quad (4.3)$$

Toute valeur  $D(i, j)$  donne la différence, au sens de DTW, entre les  $i$  premiers éléments de  $t_1$  et les  $j$  premiers éléments de  $t_2$  (par conséquent le critère DTW  $D_{dtw}(t_1, t_2)$  correspond à  $D(m, n)$ ).

Nous donnons ci-dessous une illustration de l'approche décrite. Nous cherchons à comparer deux séries temporelles :  $t_1 = (2, 3, 6, 9, 5, 4, 3)$  de taille  $m = 7$  et  $t_2 = (1, 2, 5, 9, 4, 2)$  de taille  $n = 6$ . Les matrices de pénalité  $P$  et de distance  $D$  correspondantes se lisent :

$$\begin{array}{c}
 \begin{array}{c} P(i,j)= \\ t_2 \end{array} \\
 \begin{array}{c} 1 \quad 2 \quad 5 \quad 9 \quad 4 \quad 2 \quad i= \\ \hline t_1 \quad 2 \quad 1 \quad 0 \quad 3 \quad 7 \quad 2 \quad 0 \quad 1 \\ \quad 3 \quad 2 \quad 1 \quad 2 \quad 6 \quad 1 \quad 1 \quad 2 \\ \quad 6 \quad 5 \quad 4 \quad 1 \quad 3 \quad 2 \quad 4 \quad 3 \\ \quad 9 \quad 8 \quad 7 \quad 4 \quad 0 \quad 5 \quad 7 \quad 4 \\ \quad 5 \quad 4 \quad 3 \quad 0 \quad 4 \quad 1 \quad 3 \quad 5 \\ \quad 4 \quad 3 \quad 2 \quad 1 \quad 5 \quad 0 \quad 2 \quad 6 \\ \quad 3 \quad 2 \quad 1 \quad 2 \quad 6 \quad 1 \quad 1 \quad 7 \\ \hline j = \quad 1 \quad 2 \quad 3 \quad 4 \quad 5 \quad 6 \end{array} \\
 \begin{array}{c} D(i,j)= \\ t_2 \end{array} \\
 \begin{array}{c} 1 \quad 2 \quad 5 \quad 9 \quad 4 \quad 2 \quad i= \\ \hline t_1 \quad 2 \quad 1 \quad 1 \quad 4 \quad 11 \quad 13 \quad 13 \quad 1 \\ \quad 3 \quad 3 \quad 2 \quad 3 \quad 9 \quad 10 \quad 11 \quad 2 \\ \quad 6 \quad 8 \quad 6 \quad 3 \quad 6 \quad 8 \quad 12 \quad 3 \\ \quad 9 \quad 16 \quad 13 \quad 7 \quad 3 \quad 8 \quad 15 \quad 4 \\ \quad 5 \quad 20 \quad 16 \quad 7 \quad 7 \quad 4 \quad 7 \quad 5 \\ \quad 4 \quad 23 \quad 18 \quad 8 \quad 12 \quad 4 \quad 6 \quad 6 \\ \quad 3 \quad 25 \quad 19 \quad 10 \quad 14 \quad 5 \quad 5 \quad 7 \\ \hline j = \quad 1 \quad 2 \quad 3 \quad 4 \quad 5 \quad 6 \end{array}
 \end{array} \tag{4.4}$$

La trajectoire optimale  $W = [(1, 1), (1, 2), D(2, 2), (3, 3), (4, 4), (5, 5), (6, 5), (7, 6)]$  est représentée en rouge, elle est composée de 8 éléments et utilisée pour le calcul de la DTW. La somme normalisée des pénalités cumulée le long du chemin optimal se lit  $D(7, 6) = D_{dtw}(t_1, t_2) = 5$ .

Dans cette thèse, de tels critères de déformation temporelle ont été inclus dans plusieurs techniques de classification. En premier lieu, deux approches basées sur le critère DTW de la relation (équation 4.2) ont été proposées. Dans un second temps, nous avons testé une méthode basée sur l'ensemble des chemins  $w$  possibles entre les séries  $t_1$  et  $t_2$ . Ainsi, nous avons trois techniques de classification dédiées aux séries temporelles :

1. KNN au sens de DTW. Ici, le critère  $D_{dtw}(t_1, t_2)$  entre les séries  $t_1$  et  $t_2$  remplace la norme  $L_2$  dans une technique aux plus proches voisins. Nous noterons cette technique  $KNN_{dtw}$  ;
2. DTW dans un noyau SVM. Ici, le critère  $D_{dtw}(t_1, t_2)$  remplace la norme  $L_2$  dans le noyau gaussien de la relation 1.4.1.4.1.2 couramment utilisée dans la technique SVM (cf. section 1.4.1.4, page 53). Ce nouveau noyau s'écrit [Bahmann *et al.* 2002, Shimodaira *et al.* 2001, Zhang *et al.* 2010] :

$$k(t_1, t_2) = \langle \phi(t_1), \phi(t_2) \rangle = \exp(-\gamma D_{dtw}^2(t_1, t_2)), \tag{4.5}$$

$\gamma$  étant un paramètre à fixer. Cette technique sera notée  $SVM_{dtw}$  ;

3. Noyau GAK (pour *Global Alignment Kernel*) dans une technique SVM. Ce noyau ne s'appuie plus sur le chemin optimal mais prend en compte tous les chemins possibles. Il est en effet prouvé que le noyau (équation 4.5) souffre de certaines limitations théoriques car il n'est pas toujours défini-positif [Haasdonk & Keysers 2002, Lei & Sun 2007, Zhang *et al.* 2010] ce qui ne respecte pas certaines propriétés que les noyaux doivent avoir. Cela peut conduire certains cas *dégénérés*, engendrant des résultats incohérents. Nous avons donc choisi de tester un noyau qui prend en compte tous les chemins [Cuturi *et al.* 2007, Cuturi 2011] :

$$k(t_1, t_2) = \langle \phi(t_1), \phi(t_2) \rangle = \sum_{\pi \in \mathcal{w}} \prod_{i=1}^{|\pi|} g(t_{\pi_{i,1}}, t_{\pi_{i,2}}) \tag{4.6}$$

où  $w$  est l'ensemble des chemins possibles entre les séries  $t_1$  et  $t_2$ ,  $\pi_{i,1}$  (resp.  $\pi_{i,2}$ ) étant le premier

(resp. second) composant de  $\pi(i)$  et  $g$  est une fonction gaussienne :  $g(\mathbf{t}_1, \mathbf{t}_2) = \exp(-\gamma|\mathbf{t}_1 - \mathbf{t}_2|^2)$ . Il a été démontré dans [Cuturi *et al.* 2007] que ce noyau est symétrique et défini positif. Cette technique sera notée  $\text{SVM}_{gak}$  (pour *Global Alignment Kernel*).

Par conséquent, nous allons comparer ces trois techniques de classification aux deux méthodes plus standards (KNN et SVM), basées sur la norme  $L_2$ , présentées dans la section 1.4.1.4, page 53. Cela nous permettra d'évaluer les intérêts de tels critères temporels pour l'analyse de séries temporelles complexes issues de données de télédétection.

Tous les paramètres internes (nombre de voisins pour KNN,  $\gamma$  dans SVM) sont estimés par validation croisée (« k-fold cross validation ») [Kohavi 1995], qui est une méthode d'estimation de fiabilité d'un modèle par échantillonnage. En pratique, l'ensemble d'apprentissage est partagé de manière aléatoire en  $k$  sous-échantillons de taille identique. Les différentes techniques de classification sont appliquées sur un ensemble de paramètres variable où les  $k - 1$  sous-échantillons sont utilisés comme données d'entraînement et le restant comme donnée de validation. Ce processus est répété en changeant les sous-échantillons d'entraînement/validation et la combinaison optimale des paramètres est retenue pour la classification. La validation croisée est une méthode couramment utilisée pour fixer les paramètres internes aux méthodes de classification.

### 4.1.3. Résultats

#### 4.1.3.1. Analyse de l'évolution temporelle du LAI

##### 4.1.3.1.1. Données simulées

Les séries temporelles simulées sont illustrées sur la figure 4.3. On peut observer que toutes les séries d'une classe donnée ont des formes similaires, mais qu'elles peuvent être décalées dans le temps. Ces séries asynchrones visent à simuler les futures séries temporelles qui seront disponibles avec les satellites à venir comme Sentinel-2.

La gestion des prairies repose sur la croissance de l'herbe qui dépend principalement des conditions climatiques et des sols, le climat tempéré doux avec des sols profonds et riches étant les conditions les plus favorables pour la pousse de l'herbe. L'herbe pousse peu lorsque les températures sont inférieures à  $5^\circ\text{C}$ , mais pousse rapidement dans des conditions chaudes et humides caractéristiques des mois d'avril, mai et juin en Europe du nord-ouest. Durant cette période, la croissance de l'herbe est généralement plus élevée que les besoins en nourriture du bétail. Ainsi, les agriculteurs peuvent exploiter certaines parcelles pour l'ensilage ou la production de foin pour constituer les réserves en fourrage pour l'hiver. Pendant la période estivale, l'herbe pousse moins rapidement, les parcelles sont alors utilisées pour le pâturage. On parle alors d'exploitation mixte des parcelles (pâturage et fauche sur la même parcelle durant la saison végétative) (Figure 4.3-c). Les agriculteurs peuvent aussi utiliser les prairies exclusivement en fauche, avec deux à trois coupes par an entre fin mai et septembre (Figure 4.3-b). Enfin, les agriculteurs peuvent utiliser les prairies exclusivement pour le pâturage au cours de la saison végétative de mars à octobre (Figure 4.3-a).

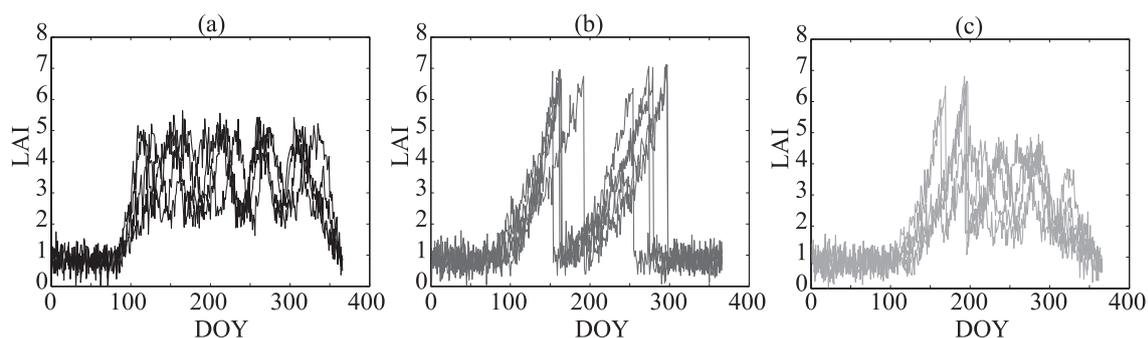


Figure 4.3 – Exemple de profils temporels simulés de LAI pour les trois modes de gestion des prairies : pâturage (a), fauche (b) et exploitation mixte (c)

#### 4.1.3.1.2. Données réelles

Les séries temporelles réelles ont été obtenues à partir des données satellites HRS disponibles sur la saison végétative de 2006, soit cinq images acquises aux jours de l'année (DOY) 76, 96, 152, 199 et 266 (Figure 4.4). Malgré la faible taille de ces séries, nous avons néanmoins testé les algorithmes sur ces données afin d'évaluer la capacité des critères de distance « élastique » sur de petites séries. Comme dans la figure 4.3, les trois modes de gestion sont identifiables. Toutefois, en raison du faible nombre de données, seuls quelques éléments clés sont visibles :

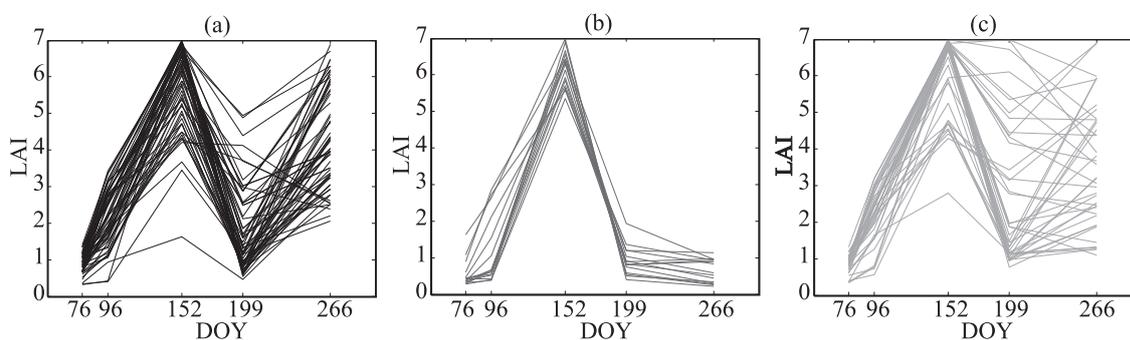


Figure 4.4 – Exemple de profils temporels réels de LAI pour les trois modes de gestion des prairies : pâturage (a), fauche (b) et exploitation mixte (c) (Mars, DOY :76 ; Avril, DOY :96 ; Juin, DOY :152 ; Juillet, DOY :199 ; Septembre, DOY :266)

- Les deux premières dates (DOY 76 et 96) correspondant au début de la période de croissance de la végétation intègrent des valeurs faibles de LAI ;
- La troisième image ayant été acquise pendant la période de forte croissance de la végétation (Juin, DOY 152), on peut observer le pic de LAI ;
- Les deux dernières images (DOY 199 et 266) montrent des valeurs différentes en fonction des modes de gestion en place.

Il convient de souligner que l'écart entre l'image acquise en juillet (DOY 199) et celle acquise en septembre (DOY 266) est assez conséquent. Ainsi, des informations sur la croissance de la végétation et des pratiques agricoles sont manquantes, notamment pour la pratique de la fauche (absence d'information sur une éventuelle seconde croissance de la végétation -et donc une seconde fauche-, cf.

figure 4.4b). Par conséquent, les séries temporelles de la figure 4.4 peuvent être considérées comme des sous-échantillons des séries simulées de la figure 4.3. Les trois modes de gestion sont associés à des valeurs de LAI similaires pour les dates de mars et avril (DOY 76 et 96, respectivement) correspondant à la période de croissance de la végétation, tandis que les profils correspondant à la pratique mixte présentent une grande dispersion autour de la moyenne. De leur côté, les profils correspondant à la pratique de la fauche présentent un faible écart-type associé néanmoins à des changements globalement plus brusques.

Pour aller plus dans le détail sur l'analyse des séries temporelles issues des données satellites, la figure 4.5-a représente la variance intra-classe des séries et illustre que les valeurs de LAI des classes pâturage et exploitation mixte sont caractérisées par de fortes variances intra-classe pour les mois de juin, juillet et septembre (DOY 152, 199 et 266, respectivement), en raison de la diversité des pratiques, à l'inverse des séries de la classe fauche qui s'illustrent par de faibles variances intra-classe.

De plus, la variance inter-classe de septembre (DOY 266) est élevée, notamment entre la fauche et le pâturage d'une part et entre la fauche et l'exploitation mixte d'autre part (Figure 4.5-b). Par ailleurs, la variance inter-classe de juillet (DOY 199) est élevée entre l'exploitation mixte et le pâturage d'une part et entre l'exploitation mixte et la fauche d'autre part. Ainsi, les variances inter et intra classe soulignent le caractère saisonnier de la croissance de la végétation et des modes de gestion qui en découlent.

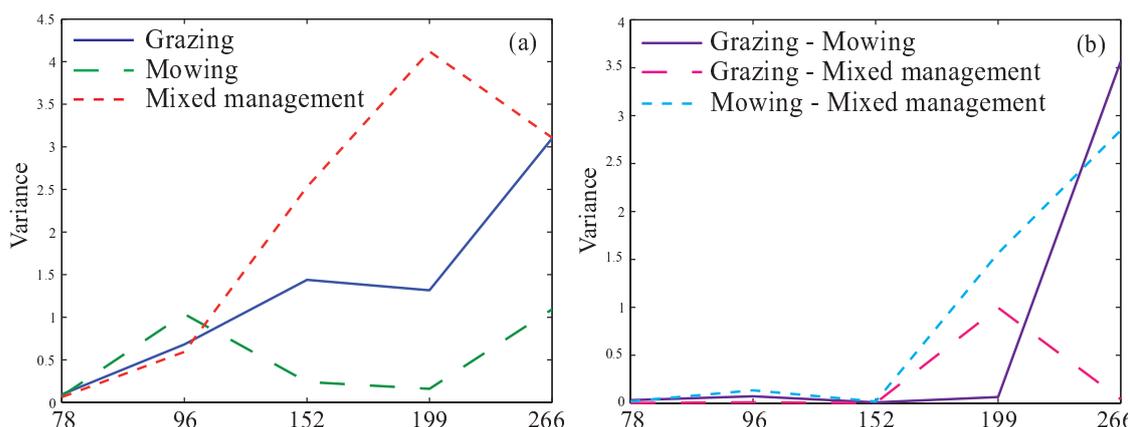


Figure 4.5 – Illustration de la variance intra-classe (a) et de la variance inter-classe (b) pour chaque date d'acquisition

Nous allons maintenant évaluer les performances des différentes techniques de classification sur deux types de données.

#### 4.1.3.2. Performances des méthodes de classification des séries temporelles

##### 4.1.3.2.1. Résultats sur des données simulées

Les résultats de classification obtenus avec les profils simulés sont présentés dans le tableau 4.1. Il est d'abord intéressant d'observer que les Kappa obtenus avec les deux algorithmes KNN et SVM sans l'utilisation de métriques temporelles sont faibles : 0.65 et 0.24, respectivement. Évidemment, le fait que les séries temporelles soient décalées dans le temps génère des erreurs avec des mesures de

distance classiques (comme la norme  $L_2$ ) car les séries que nous cherchons à classer, même si elles présentent des tendances similaires pour chacune des classes, sont très difficiles à discriminer sur la base d'une comparaison date par date. Pour de telles situations, des méthodes basées sur des critères temporels seraient plus appropriées pour classer ces séries. Ainsi, les résultats de classification utilisant ces critères sont nettement améliorés même avec une technique de classification simple comme KNN : l'indice de Kappa passe à 0.72 avec ce dernier. Les résultats sont encore nettement améliorés avec la technique SVM<sub>dtw</sub> et encore plus avec SVM<sub>gak</sub> avec un Kappa de 0.93. Par conséquent, ces résultats montrent la capacité des mesures de distance « élastique » (DTW) et des noyaux spécifiques basés sur ces distances pour classer correctement des séries temporelles complexes. Ces résultats sont très encourageants et prometteurs, en particulier en vue de l'exploitation des futures séries temporelles issues des capteurs Venμs et Sentinel-2.

Tableau 4.1 – Performances de classification des différents algorithmes appliqués au jeu de données simulées (Classe 1 : pâturage, classe 2 : fauche et classe 3 : exploitation mixte)

		Without temporal measurements (%)		With temporal measurements (%)		
Technique		KNN	SVM	KNN <sub>dtw</sub>	SVM <sub>dtw</sub>	SVM <sub>gak</sub>
Class 1	Well classified	80	100	91	93	87
	Omission error	20	0	9	7	13
	Commission error	0	151	4	0	0
Class 2	Well classified	51	20	76	80	100
	Omission error	49	80	24	20	0
	Commission error	0	0	11	0	0
Class 3	Well classified	100	71	85	98	100
	Omission error	0	29	15	2	0
	Commission error	69	0	40	27	13
<b>Overall kappa</b>		0.65	0.24	0.72	0.86	<b>0.93</b>

#### 4.1.3.2.2. Résultats sur des données réelles

Les résultats de classification obtenus avec les profils réels sont présentés dans le tableau 4.2. Comme pour les profils simulés, la technique KNN montre de meilleurs résultats que la technique SVM quand aucun critère temporel n'est pris en compte dans la mesure de distance. Le fait que KNN ne fasse aucune hypothèse sur les propriétés mathématiques des échantillons peut expliquer cette observation. Au contraire, avec la technique SVM, un séparateur non linéaire est recherché et comme aucune solution optimale existe sur la base de la norme  $L_2$ , le séparateur n'a pas de réelle signification ce qui conduit à des résultats médiocres.

Si on observe maintenant les résultats obtenus avec KNN<sub>dtw</sub>, SVM<sub>dtw</sub> et SVM<sub>gak</sub>, il est important de noter qu'ils sont tous acceptables en particulier avec la technique SVM (Kappa de 0.83 et 0.82, respectivement) malgré le fait qu'il n'y ait que peu de données et qu'une grande confusion visuelle entre les classes existe. Ici, même avec de telles données complexes, les critères de distance adaptés aux séries temporelles sont nettement plus adaptés que la norme  $L_2$ , ce qui constitue un résultat très intéressant, notamment dans un contexte d'augmentation des données temporelles.

De manière plus détaillée, nous pouvons observer que la classe 3 (exploitation mixte) est généralement surestimée par rapport à la classe 1 (pâturage) et la classe 2 (fauche), en particulier avec

les classifications non basées sur des mesures temporelles (Tableau 4.2). La classe 2 est globalement sous-estimée en faveur de la classe 3 jusqu'à 40% du total des échantillons de fauche en utilisant les algorithmes KNN et SVM sans mesures temporelles. La classe 3 est sous-estimée en faveur de la classe 1 jusqu'à 29% en utilisant le KNN et jusqu'à 57% en utilisant le SVM sans mesures temporelles. Dans une moindre mesure, les classifications KNN et SVM basées sur des mesures temporelles montrent que les classes 1 et 2 sont globalement sous-estimées en faveur de la classe 3.

Tableau 4.2 – Performances de classification des différents algorithmes appliqués au jeu de données réelles (Classe 1 : pâturage, classe 2 : fauche et classe 3 : exploitation mixte)

		Without temporal measurements (%)		With temporal measurements (%)		
Technique		KNN	SVM	KNN <sub>dtw</sub>	SVM <sub>dtw</sub>	SVM <sub>gak</sub>
Class 1	Well classified	95	100	84	88	86
	Omission error	5	0	16	12	14
	Commission error	17	28	11	5	4
Class 2	Well classified	60	60	78	84	86
	Omission error	40	40	22	16	14
	Commission error	0	0	0	0	0
Class 3	Well classified	71	43	86	94	95
	Omission error	29	57	14	6	5
	Commission error	23	25	24	17	18
<b>Overall kappa</b>		0.69	0.54	0.72	<b>0.83</b>	0.82

#### 4.1.4. Conclusion

Dans cette partie, nous avons évalué (1) la capacité d'une série temporelle d'images optiques à haute résolution spatiale à identifier les modes de gestion des prairies et (2) la performance de méthodes de classification dans ce contexte de séries temporelles complexes. Les résultats ont montré l'intérêt de l'utilisation de méthodes qui s'appuient sur des critères de comparaisons adaptés à l'aspect temporel des données. Ainsi, des résultats très satisfaisants ont été obtenus pour la caractérisation des prairies même avec l'utilisation de séries temporelles réduites, ouvrant des perspectives intéressantes pour l'utilisation des futures séries temporelles à haute résolution spatiale et temporelle.



## 4.2. Comparaison inter-annuelle de séries temporelles d'images optiques et/ou radars pour identifier les modes de gestion des prairies

---

---

---

### CONTENTS

4.2.1	Introduction . . . . .	157
4.2.2	Méthodologie . . . . .	157
4.2.2.1	Les données . . . . .	157
4.2.2.2	Classification des séries temporelles . . . . .	158
4.2.3	Résultats . . . . .	158
4.2.3.1	Analyse de la séparabilité . . . . .	158
4.2.3.1.1	Séparabilité avec la série d'images acquise en 2010 . . . . .	158
4.2.3.1.2	Séparabilité avec la série d'images acquise en 2011 . . . . .	161
4.2.3.2	Classification des séries optiques et radars . . . . .	162
4.2.4	Conclusion . . . . .	164

---

Le contenu de cette partie sera intégré dans l'article suivant :  
**P. Dusseux**, T. Corpetti. and L. Hubert-Moy  
*Exploitation de séries temporelles d'images satellites à haute résolution spatiale  
pour l'étude des modes de gestion des prairies.*  
Revue Internationale de Géomatique, soumission fin 2014.



## 4.2.1. Introduction

Dans cette partie, nous chercherons à combiner des données optiques avec des données radars à haute résolution spatiale pour évaluer leur intérêt pour identifier des modes de gestion des prairies.

Dans la partie précédente, nous avons montré que des séries temporelles d'images optiques permettaient d'identifier les modes de gestion des prairies avec une précision satisfaisante ( $K=0.83$ ). Dans le chapitre précédent, nous avons aussi montré que l'utilisation de la synergie optique-radar permettait d'améliorer l'identification des prairies comparativement à l'utilisation des données optiques seules. Nous avons aussi mis en évidence que les images radars acquises en mode « Quad-pol » combinées avec les données optiques, permettaient d'obtenir des taux de précision supérieurs aux taux réalisés avec les images radars acquises en mode « Ultra-fin » combinées avec les données optiques. Par ailleurs, nous avons démontré la supériorité des méthodes de classification prenant en compte une mesure temporelle pour classer les profils de paramètres issus des images de télédétection comparativement aux méthodes qui n'en utilisent pas. Il apparaît donc intéressant (1) d'évaluer l'intérêt de la synergie optique-radar pour identifier les modes de gestion des prairies, (2) de valider la supériorité du mode « Qual-pol » sur le mode « Ultra-fin » et (3) de confirmer l'intérêt de l'utilisation de mesures temporelles dans le processus de classification des séries temporelles d'images.

Pour cela, nous avons classé les paramètres dérivés de quatre séries temporelles, deux optiques et deux radars : le LAI pour les deux séries optiques, tous les coefficients de rétrodiffusion et les paramètres polarimétriques pour la série radar acquise en mode « Qual-pol » et le coefficient de rétrodiffusion VV pour la série radar acquise en mode « Ultra-fin ».

## 4.2.2. Méthodologie

### 4.2.2.1. Les données

Pour cette partie, deux séries d'images optiques et deux séries d'images radars à haute résolution spatiale acquises en 2010 et 2011 ont été utilisées pour identifier les modes de gestion des prairies. La série de l'année 2010 comprend quatre images optiques et cinq images radars et la série de 2011 cinq images optiques et quatre images radars (Tableau 1.6, page 48 et tableau 1.8, page 52). Les pré-traitements et traitements réalisés sur les images satellites ont été détaillés dans la section 1.4 (page 47). Des relevés d'occupation des sols ont aussi été effectués chaque mois sur le site d'étude afin de calibrer et valider la classification des images satellites.

Le LAI ayant été évalué comme étant le paramètre le plus pertinent pour étudier les prairies, seul ce paramètre a été conservé pour les séries optiques (Chapitre ??). Concernant les données radars acquises en 2010 en mode « Quad-Pol » les coefficients de rétrodiffusion en  $\sigma^0$  (dB), les ratios d'intensité (HH/VV, HH/HV et VV/HV) et les paramètres issus de deux décompositions polarimétriques (Freeman-Durden [Freeman *et al.* 1994] et Cloude-Pottier [Cloude & Pottier 1997], cf. section 1.2, page 11) ont été calculés et évalués pour identifier les modes de gestion des prairies. Les données radars acquises en 2011 en mode « Ultra-fin » se composant d'une seule polarisation, seul le coefficient de rétrodiffusion VV en  $\sigma^0$  (dB) a été utilisé et évalué.

### 4.2.2.2. Classification des séries temporelles

Afin d'évaluer et de comparer la capacité des paramètres extraits des données satellites pour la caractérisation des prairies, la divergence transformée ( $TD$ ) a été calculée pour tous les paramètres considérés (Section 3.2.1, page 113), cette mesure permettant d'évaluer la capacité d'un paramètre à discriminer deux classes différentes.

Ensuite, les méthodes de classification présentées dans la partie précédente (Section 4.1) ont été appliquées sur les différents jeux de données. L'indice de Kappa ( $K$ ) a été utilisé pour évaluer la précision des classifications [Congalton 1991].

### 4.2.3. Résultats

Dans un premier temps, la séparabilité entre les classes est étudiée pour chacun des paramètres considérés et pour les deux années étudiées ; Dans un second temps, les résultats de classification sont présentés.

#### 4.2.3.1. Analyse de la séparabilité

##### 4.2.3.1.1. Séparabilité avec la série d'images acquise en 2010

Les valeurs de divergence transformée ( $TD$ ) entre les trois modes de gestion des prairies (pâturage, fauche, mixte) calculées à partir des profils temporels de LAI dérivés des images optiques et des profils temporels des paramètres extraits des données radars de l'année 2010 sont présentées dans le tableau 4.3. D'après les valeurs de  $TD$  obtenues avec la variable LAI, la série temporelle optique de 2010 semble adaptée pour séparer la fauche de la pâture et la fauche de l'exploitation mixte. En revanche, la séparation entre le pâturage et l'exploitation mixte semble plus difficile avec ce paramètre. Les valeurs de  $TD$  obtenues avec les paramètres radars sont globalement très faibles ( $< 1.7$ ), indiquant une grande confusion entre les profils temporels des trois modes de gestion des prairies. Cependant, on peut observer que l'utilisation de trois paramètres, comme avec la combinaison des trois polarisations (HH, VV et HV) et les deux décompositions polarimétriques (Freeman-Durden et Cloude-Pottier), permet d'obtenir des valeurs de  $TD$  plus élevées (égales à 2) permettant ainsi une meilleure séparation. Ce constat est cependant à relativiser car il a été démontré dans [Thomas *et al.* 1987] que plus le nombre de paramètres augmente, plus la mesure de séparabilité est élevée même si les classes ne sont pas séparables.

Les profils temporels de LAI et du coefficient de rétrodiffusion HH sont illustrés par la figure 4.6. On peut observer que le LAI permet de bien distinguer les profils correspondant aux parcelles pâturées et aux parcelles fauchées au cours de la saison végétative. En effet, on constate un pic de croissance à la fin du mois de mai (DOY 141) pour les parcelles destinées à la fauche puis une chute importante des valeurs de LAI à la fin juin (DOY 177) suite à la fauche. L'image acquise en septembre (DOY 254) montre deux types de valeurs pour ces parcelles : élevées pour les parcelles n'ayant pas encore été fauchées, faibles pour les parcelles déjà fauchées. Les parcelles destinées au pâturage ont quant à elles, des profils plus variés durant la saison végétative, les dates de pâturage variant d'une parcelle à l'autre. Ainsi, pour discriminer les profils des parcelles pâturées des profils des parcelles fauchées seules les valeurs du mois de juin ont été utilisées (valeurs supérieures à 3 pour des parcelles pâturées et inférieures à 2.5 pour les parcelles fauchées). En revanche, les profils des parcelles pâturées et des

Tableau 4.3 – Valeurs de la divergence transformée entre les modes de gestion des prairies pour le LAI et les paramètres radars (séries temporelles de l'année 2010)

Variable set	Practices		
	Grazing-Mowing	Grazing-Mixed	Mowing-Mixed
<b>Optical VARIABLE</b>			
LAI	1.89	1.45	1.75
<b>SAR VARIABLES</b>			
<b>Single polarization</b>			
$\sigma^0_{HH}$	1.72	1.69	1.35
$\sigma^0_{VV}$	1.33	1.52	1.43
$\sigma^0_{HV}$	1.06	1.56	1.64
<b>Combination of polarizations</b>			
HH, VV, HV	2.00	2.00	2.00
<b>Polarization ratio</b>			
HH/VV	1.65	1.7	1.43
HH/HV	1.73	1.15	1.36
VV/HV	1.27	0.67	0.44
<b>Polarimetric decomposition</b>			
Freeman-Durden	2.00	2.00	2.00
<i>Double Bounce</i>	1.3	1.46	1.67
<i>Volume Scattering</i>	0.89	1.1	1.17
<i>Rough Surface</i>	1.31	0.51	0.88
Cloude-Pottier	2.00	2.00	2.00
<i>Entropy</i>	1.64	1.44	1.4
<i>Anisotropy</i>	0.67	0.6	1.07
<i>Alpha</i>	1.21	1.35	1.5

parcelles soumises à une exploitation mixte sont très difficiles à différencier.

L'analyse des profils temporels du coefficient de rétrodiffusion HH extrait des données radars montre qu'il n'est pas possible de les utiliser pour distinguer les trois modes de gestion. Tous les profils montrent les mêmes évolutions au cours de la saison végétative. Ainsi, les modifications d'état de surface des parcelles ne sont pas assez importantes pour modifier le signal rétrodiffusé et différencier ces trois pratiques.

Nous avons vu qu'en utilisant les trois paramètres issus de chacune des deux décompositions polarimétriques (Freeman–Durden ou Cloude–Pottier) les valeurs de  $TD$  étaient égales à 2. Cependant, en analysant les figures 4.7 et 4.8 nous n'observons aucune distinction entre les trois modes de gestion des prairies. Le mécanisme de surface, qui est le mécanisme dominant des prairies, est caractérisé par une très faible entropie. Selon Cloude–Pottier (1997) de faibles valeurs d'entropie ( $H < 0.5$ ) présentent moins d'intérêt et de détails que des valeurs d'entropie plus élevées. De ce fait, la distinction des modes de gestion des prairies avec une série temporelle Radatsat-2 semble difficile.

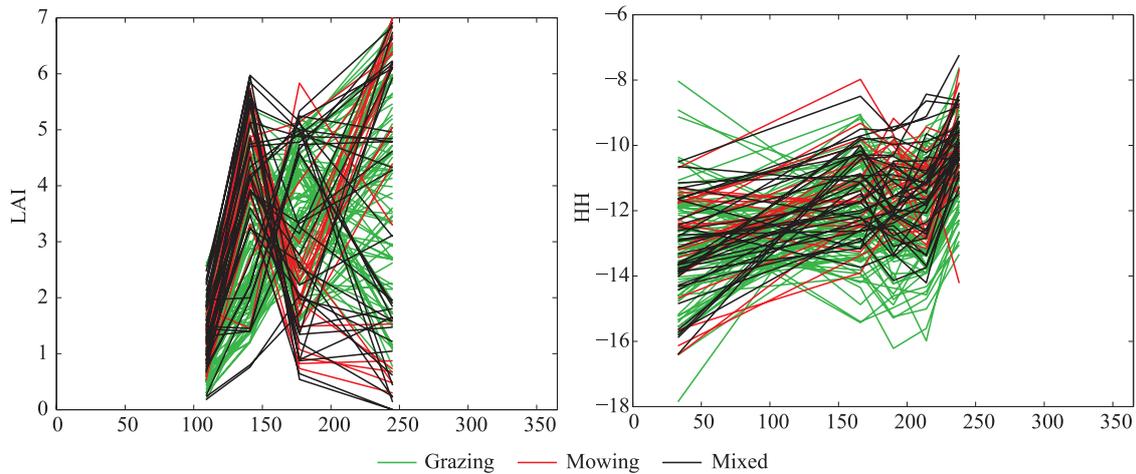


Figure 4.6 – Profils temporels de LAI et du coefficient de rétrodiffusion HH correspondant aux parcelles enquêtées pour les trois modes de gestion

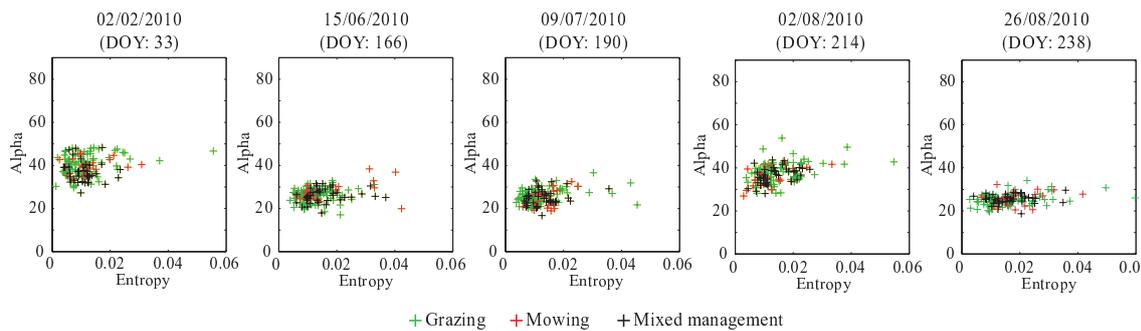


Figure 4.7 – Représentation des trois modes de gestion dans l'espace entropie (H) et alpha ( $\alpha$ ), variables dérivées de la décomposition de Cloude–Pottier, pour chaque date d'acquisition

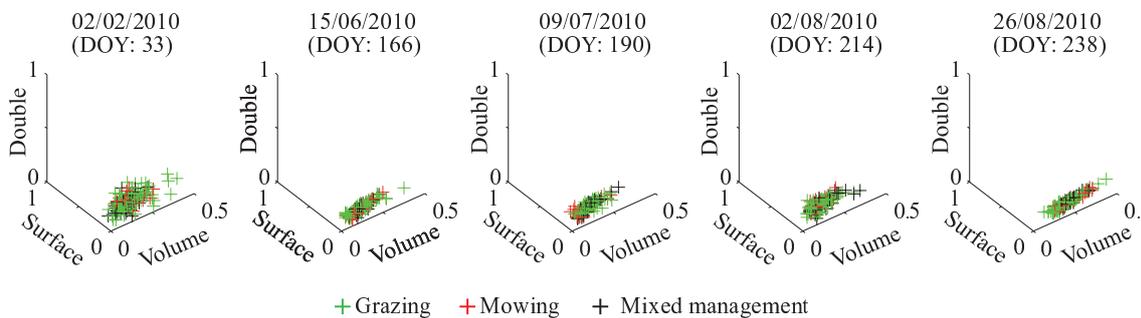


Figure 4.8 – Représentation des trois modes de gestion dans l'espace comprenant les variables volume, surface et double rebond dérivées de la décomposition de Cloude–Pottier pour chaque date d'acquisition

#### 4.2.3.1.2. Séparabilité avec la série d'images acquise en 2011

Les valeurs de divergence transformée ( $TD$ ) entre les trois modes de gestion des prairies (pâturage, fauche, mixte) calculées à partir des profils temporels de LAI dérivés des images optiques et des profils temporels du coefficient de rétrodiffusion HH issus des données radars de l'année 2011 sont présentées dans le tableau 4.4. D'après ce tableau, on constate que la série temporelle de LAI permet de correctement séparer la fauche de la pâture. En revanche, la séparation entre le pâturage et l'exploitation mixte et la fauche et l'exploitation mixte semble plus difficile. Les valeurs de  $TD$  obtenues avec le coefficient de rétrodiffusion VV sont très faibles et ne permettent pas de discriminer les différents modes de gestion.

Tableau 4.4 – Valeurs de la divergence transformée entre les modes de gestion des prairies pour le LAI extrait des images optiques et le coefficient de rétrodiffusion HH issu des données radars pour l'année 2011

Variable set	Practices	Grazing-Mowing	Grazing-Mixed	Mowing-Mixed
<b>Optical VARIABLE</b>				
LAI		1.85	1.30	1.36
<b>SAR VARIABLE</b>				
VV		1.32	1.08	0.76

Les profils temporels de LAI et du coefficient de rétrodiffusion VV sont illustrés par la figure 4.9. On peut observer que les profils temporels des classes pâturage et fauche présentent des formes différentes. En effet, on observe que les profils de LAI pour les parcelles fauchées présentent un pic de croissance en mai (DOY 143) suivi par une très forte baisse des valeurs de LAI en août (DOY 222) suite à une ou plusieurs fauches. Les parcelles pâturées présentent, quant à elles, des valeurs plus faibles en mai (DOY 143) car des pâturages ont déjà eu lieu (de plus pour ce mode de gestion, l'herbe n'est pas laissée pousser autant que pour la fauche). L'analyse des profils temporels issus des données radars montre qu'ils ne sont pas utilisables pour distinguer les trois modes de gestion. Les valeurs sont relativement constantes au cours de la saison végétative, ce qui ne permet pas d'identifier une fauche ou un pâturage.

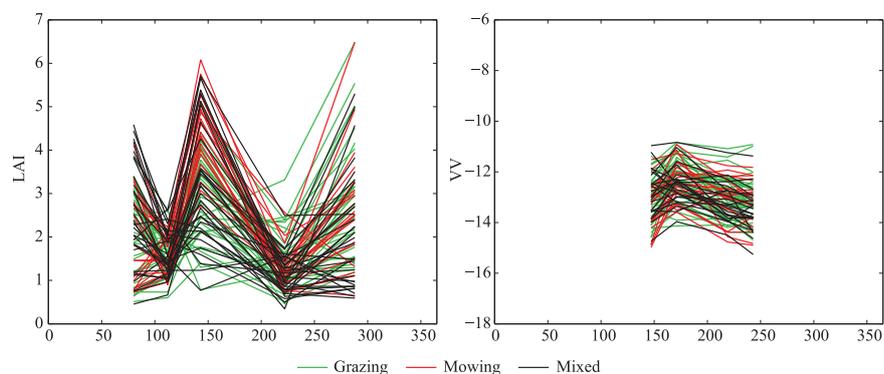


Figure 4.9 – Profils temporels de LAI et du coefficient de rétrodiffusion VV correspondant aux parcelles enquêtées pour les trois modes de gestion

### 4.2.3.2. Classification des séries optiques et radars

Les tableaux 4.5, 4.6, 4.7 présentent les valeurs de Kappa obtenues avec les méthodes de classification  $KNN$ ,  $SVM$ ,  $SVM_{dtw}$  et  $SVM_{gak}$  appliquées à des séries temporelles de LAI acquises en 2010 et en 2011, et aux paramètres radars des séries temporelles acquises en 2010 et en 2011.

Tableau 4.5 – Valeurs de Kappa obtenues pour la classification des séries temporelles de LAI acquises en 2010 et en 2011 avec et sans utilisation de métriques temporelles

	Without temporal measurements		With temporal measurements	
	KNN	SVM	$SVM_{dtw}$	$SVM_{gak}$
2010	0.61	0.54	0.73	0.75
2011	0.58	0.45	0.70	0.75

Tableau 4.6 – Valeurs de Kappa obtenues pour la classification des trois paramètres dérivés de la série temporelle radar acquise en 2010

	KNN	SVM	$SVM_{dtw}$	$SVM_{gak}$
HH, VV, HV	0.20	0.07	0.23	0.41
Freeman–Durden	0.15	0.18	0.30	0.31
Cloude–Pottier	0.08	0	0.29	0.33

Tableau 4.7 – Valeurs de Kappa obtenues pour la classification du paramètre dérivé de la série temporelle radar acquise en 2011

	KNN	SVM	$SVM_{dtw}$	$SVM_{gak}$
VV	0.18	0.14	0.08	0.08

L'analyse des résultats obtenus avec les séries de LAI acquises en 2010 et en 2011 concorde avec ceux qui ont été obtenus avec la série temporelle de LAI acquise en 2006 (section 4.1). En effet, les résultats sont légèrement meilleurs avec la technique KNN qu'avec la technique SVM quand aucun critère temporel n'est pris en compte dans la mesure de distance. Cependant, la précision des classifications reste faible et non acceptable pour la cartographie des pratiques agricoles réalisées sur les prairies. Si on observe les résultats obtenus avec  $SVM_{dtw}$  et  $SVM_{gak}$ , on constate une amélioration de la précision de la classification, le Kappa atteignant 0.75 pour les deux séries temporelles. Ainsi, dans le cadre de l'exploitation de données complexes il est important d'utiliser une mesure de distance prenant en compte l'aspect temporel des séries de données afin de mieux discriminer les différentes pratiques agricoles.

Les matrices de confusion issues de la classification des séries temporelles de LAI acquises en 2010 et en 2011 sont représentées dans le tableau 4.8. Nous pouvons observer que pour les deux années la classe exploitation mixte est sous-estimée par rapport aux deux autres modes de gestion (pâturage et fauche). En effet, ce mode de gestion présente des pratiques intermédiaires entre le pâturage et

la fauche et les séries temporelles utilisées ne contiennent pas suffisamment de détails pour pouvoir identifier correctement l'utilisation mixte.

Tableau 4.8 – Matrices de confusion (en %) issues des classifications utilisant la méthode de classification SVM<sub>gak</sub> et la variable LAI dérivée de séries temporelles acquises en 2010 (a) et en 2011 (b) pour identifier les modes de gestion des prairies

(a) - 2010			
	Grazing	Mowing	Mixed
Grazing	93	14	8
Mowing	0	86	23
Mixed	7	0	69
Total	100	100	100
Overall accuracy = 86%, Kappa index = 0.75.			
(b) - 2011			
	Grazing	Mowing	Mixed
Grazing	86	11	15
Mowing	7	89	8
Mixed	7	0	77
Total	100	100	100
Overall accuracy = 84%, Kappa index = 0.75.			

Si les données radars présentent un intérêt pour identifier les prairies, il n'en est pas de même pour la discrimination de leur mode de gestion, comme le montre le niveau de précision des classifications qui est très faible. En effet, les valeurs de Kappa, associées à la série Radarsat-2 acquise en mode « Quad-pol » en 2010 ou à la série Radarsat-2 acquise en mode « Ultra-fin » en 2011, ne dépassent pas 0.41. Malgré le potentiel que représentent les données Radarsat-2 en mode « Quad-pol » pour le suivi de la végétation et celui des données Radarsat-2 en mode « Ultra-fin » grâce à leur haute résolution spatiale, ces données ne permettent pas d'identifier les modes de gestion des prairies.

Les images Radarsat-2 sont enregistrées dans la bande C, celle-ci correspondant à une longueur d'onde d'acquisition moyenne (3.75-7.5cm). Plus la longueur d'onde d'acquisition est élevée, plus le rayonnement pénètre dans les surfaces. Alors que des études ont montré que le signal rétrodiffusé en bande C est généralement très faible dans les prairies malgré différentes hauteurs de végétation [Voormansik *et al.* 2013, Herold *et al.* 2001], une étude a montré qu'avec une série de onze images TerraSAR-X (enregistrées dans la bande X (2.4-3.75cm), correspondant à une longueur d'onde d'acquisition plus faible que la bande C), il est possible d'identifier les fauches réalisées sur les prairies pendant la saison végétative [Schuster *et al.* 2011]. En effet, le fait que le signal enregistré en bande X ne pénètre pas dans le couvert permet de mieux caractériser la structure de la végétation.

#### 4.2.4. Conclusion

Dans cette partie, nous avons évalué la capacité de séries temporelles d'images à haute résolution spatiale optiques et radars pour caractériser les prairies. Les résultats de classification ont montré que si les modes de gestion des prairies peuvent être identifiés avec une précision satisfaisante en utilisant des séries temporelles de LAI composées de quatre ou cinq images acquises au cours de la saison végétative, l'exploitation d'images radars n'améliore pas les résultats.

En effet, il apparaît que les paramètres extraits des données radars acquises en bande C, que ce soit en mode « Quad-pol » ou en mode « Ultra-fin », n'apportent pas d'informations sur la caractérisation des prairies puisqu'aucune amélioration sur la qualité des classifications n'est observée. Ainsi, les données Radarsat-2 ne semblent pas adaptées pour identifier les modes de gestion.

Les résultats mettent aussi en évidence que l'utilisation de méthodes adaptées pour la classification de séries temporelles, c'est-à-dire une mesure temporelle de distance, est indispensable pour classer des séries complexes avec un niveau de précision satisfaisant.

## Synthèse et conclusion du quatrième chapitre

---

Dans ce chapitre, nous avons cherché à évaluer l'apport des séries temporelles d'images de télédétection à haute résolution spatiales optiques et/ou radars pour identifier les modes de gestion des prairies. Afin de faire face à la complexité des séries temporelles de paramètres dérivés de ces images, nous avons aussi cherché à évaluer plusieurs méthodes de classification, parmi lesquelles certaines prennent en compte une mesure temporelle pour classer les profils.

Des classifications ont d'abord été réalisées sur une série temporelle de LAI dérivées d'images satellites optiques acquises en 2006. Les résultats obtenus montrent que les modes de gestion des prairies peuvent être identifiés avec des valeurs d'indice de Kappa s'élevant à 0.83, avec cinq images acquises au cours de la saison végétative. Ils mettent aussi en évidence que les méthodes de classification s'appuyant sur des critères de comparaison adaptés aux séries temporelles produisent des résultats plus satisfaisants que les méthodes standards.

Nous avons ensuite classé plusieurs séries temporelles d'images satellites, deux séries optiques et deux séries radars. Les résultats de classification ont montré que les modes de gestion des prairies peuvent être identifiés avec une précision satisfaisante en utilisant des séries temporelles de LAI composées de quatre ou cinq images acquises au cours de la saison végétative. En revanche, il apparaît que les paramètres extraits des données radars acquises en bande C, que ce soit en mode « Quad-pol » ou en mode « Ultra-fin », n'apportent pas d'informations sur la caractérisation des prairies, car les résultats de classification ont montré des précisions très faibles.

Enfin, les résultats mettent aussi en évidence que l'utilisation de méthodes adaptées pour la classification de séries temporelles, c'est-à-dire une mesure temporelle de distance, est indispensable pour classer des séries complexes avec un niveau de précision satisfaisant.

Les recherches présentées dans ce chapitre ont fait l'objet de plusieurs valorisations/publications dans des colloques nationaux et internationaux à comité de lecture :

1- **P. Dusseux**, T. Corpetti, L. Hubert-Moy, 2013. *Temporal kernels for the identification of grassland management using time series of high spatial resolution satellite images*. IGARSS'13, IEEE International Geoscience and Remote Sensing Symposium, Melbourne, Australia, 22-26 July 2013, 3258-3260.

2- **P. Dusseux**, L. Hubert-Moy, T. Corpetti, 2013. *Étude des modes de gestion des prairies : Quel peut être l'apport des séries temporelles d'images de télédétection à haute résolution spatiale ?* Journées AFPP - Prairies, systèmes fourragers et changement climatique, Paris, France, 26-27 mars 2013.

3- **P. Dusseux**, X. Gong, T. Corpetti, L. Hubert-Moy, S. Corgne, 2012. *Contribution of radar images for grassland management identification*. Proceedings SPIE 8531, Remote Sensing for Agriculture, Ecosystems, and Hydrology XIV, 853104, Edinburgh, United Kingdom, 24-27 September 2012.

---

4- **P. Dusseux**, S. Corgne, T. Corpetti, L. Hubert-Moy, 2011. *Use of optical and radar imagery at high spatial resolution for grasslands management identification*. CDSM 2011, International Symposium of Remote Sensing and GIS Methods for Change Detection and Spatio-temporal Modelling, Hong-Kong, China, 15-16 December 2011, pp. 72-74.

5- **P. Dusseux**, L. Hubert-Moy, R. Lecerf, T. Corpetti, X. Gong, 2011. *Identification of grazed and mown grasslands using a time-series of high-spatial-resolution remote sensing images*. Multitemp 2011, 6th International Workshop on the Analysis of Multi-temporal Remote Sensing Images, Trento, Italy, 12-14 July 2011, pp. 145-148.

# Conclusion Générale

Analysées indépendamment date par date, les données de télédétection disponibles jusqu'à présent ne permettent pas d'effectuer un suivi spatio-temporel détaillé des couverts prairiaux à l'échelle parcellaire sur des secteurs étendus. Nous avons ainsi émis l'hypothèse que les séries temporelles d'images à haute résolution spatiale pourraient constituer une alternative adaptée pour cette tâche. En effet, la disponibilité de séries temporelles d'images satellites constituées aujourd'hui à partir de données acquises par plusieurs capteurs et bientôt avec un seul, tel que Sentinel-2, permet désormais d'envisager d'identifier précisément les prairies et leurs modes de gestion. Toutefois, l'exploitation de ces séries temporelles d'images pose des questions d'ordre méthodologique, car il s'agit de séries de données complexes, hétérogènes et souvent incomplètes.

L'objectif principal de cette thèse était d'identifier les prairies et de déterminer leurs modes de gestion à partir de séries temporelles d'images de télédétection à haute résolution spatiale. Plus précisément, nous avons cherché à savoir s'il était possible d'estimer la place et d'identifier les modes de gestion des prairies dans les systèmes de production. Nous avons aussi cherché à évaluer et classer des paramètres dérivés de séries temporelles d'images de télédétection à haute résolution spatiale pour discriminer les prairies et déterminer leur mode de gestion. Afin d'atteindre ces objectifs, plusieurs séries intra-annuelles d'images à haute résolution spatiale optiques et radars ont été constituées afin de recenser les prairies et d'identifier trois de leurs modes de gestion, le pâturage, la fauche et l'exploitation mixte, sur un bassin versant dont le système d'exploitation dominant est l'élevage laitier. D'un point de vue thématique, les résultats obtenus à partir du traitement et de l'analyse de ces séries temporelles ont permis de montrer qu'il est possible d'estimer avec une bonne précision la biomasse des prairies et d'effectuer un suivi intra-annuel de leur état de surface conduisant à leur identification et à leur caractérisation.

Nous avons d'abord évalué le potentiel de séries temporelles d'images optiques pour estimer la biomasse et décrire l'état de surface de la végétation (hauteur, densité, homogénéité) dans des prairies. Nous avons montré, en comparant la biomasse estimée à partir des relevés effectués sur le terrain et trois paramètres qui ont été extraits à partir des images satellites optiques à haute résolution spatiale, c'est-à-dire l'indice de végétation NDVI (Normalized Difference Vegetation Index) et deux variables biophysiques, le LAI (Leaf Area Index) et le fCOVER (fraction of Vegetation Cover), que le LAI est le paramètre le plus pertinent pour estimer la biomasse des prairies (coefficient de 0.73 obtenu en utilisant cinq images SPOT). Nous avons donc considéré que la biomasse peut être estimée en utilisant des données de télédétection, ces dernières pouvant être utilisées pour estimer le stock d'herbe disponible à l'échelle d'une exploitation agricole. De plus, les résultats obtenus mettent en évidence que le LAI est aussi le paramètre le plus pertinent pour décrire l'état de surface de la végétation des prairies, ce qui permet d'identifier le pâturage et la fauche en utilisant une série limitée à trois images satellites à haute résolution spatiale [Dusseux *et al.* 2014c].

Nous avons ensuite évalué l'apport des séries temporelles d'images de télédétection à haute résolution spatiale optiques et/ou radars pour différencier les prairies des cultures [Dusseux *et al.* 2014a]. Les résultats de classifications réalisées sur trois séries intra-annuelles de LAI dérivées d'images satellites optiques montrent que les prairies peuvent être identifiées avec une très bonne précision (indice de Kappa supérieur à 0.80) avec quatre ou cinq images par an, alors que la précision de la classification obtenue avec une seule image satellite est beaucoup plus faible (indices de Kappa variant de 0.27 à 0.67). Les résultats montrent aussi que la précision de la classification varie d'une série temporelle à une autre en fonction des dates d'acquisition des images, ce qui nous a conduits à déterminer les dates optimales pour la discrimination des prairies en fonction des pratiques agricoles et des stades phénologiques des plantes. Les résultats de classifications réalisées sur deux séries intra-annuelles de paramètres dérivés d'images satellites radars, l'une acquise en mode « Quad-pol » et l'autre en mode « Ultra-fin », mettent en évidence l'intérêt de ce type de données pour identifier les prairies tout en comparant le potentiel des deux modes d'acquisition. En effet, les prairies sont discriminées avec la précision maximale (indice de Kappa égal à 1) en utilisant des paramètres issus de deux décompositions polarimétriques issues des données « Quad-pol » (des confusions subsistent entre les cultures), et une précision moyenne (Indice de Kappa de 0.67) avec le coefficient VV en mode « Ultra-fin ». Les résultats montrent aussi que l'utilisation combinée de plusieurs paramètres radars et d'un paramètre optique, le LAI, améliore les résultats avec les deux modes d'acquisition des données radars : en mode « Quad-pol » elle permet de discriminer avec une précision maximale (indice de Kappa égal à 1) les prairies et les cultures, en l'occurrence ici les céréales d'hiver et le maïs, alors que des confusions subsistaient entre les cultures en utilisant les images radars ou les images optiques exclusivement ; en mode « Ultra-fin », elle fait passer le niveau de précision de la classification de 0.83 et 0.67 quand on utilise exclusivement les données optiques ou radars respectivement à 0.88. Les résultats soulignent aussi le fait que la relation entre le LAI extrait des images optiques et les coefficients de rétrodiffusion issus des données radars varie selon le stade de développement de la végétation et en conséquence des dates d'acquisition des images. En effet, en fonction des stades phénologiques, les données radar peuvent ou non fournir une information sur l'état de la végétation (densité, hauteur, etc.) complémentaire à celle qui est extraite des images optiques.

Nous avons ensuite cherché à évaluer l'apport des séries temporelles d'images de télédétection à haute résolution spatiale optiques et/ou radars pour identifier les modes de gestion des prairies. Les résultats obtenus avec des classifications réalisées sur une série temporelle de LAI dérivées d'images satellites optiques montrent qu'ils peuvent être identifiés avec des valeurs d'indice de Kappa s'élevant à 0.83, avec cinq images acquises au cours de la saison végétative. Les résultats de classification de deux séries temporelles d'images optiques et de deux séries radars mettent en évidence que les modes de gestion des prairies peuvent être identifiés avec une précision satisfaisante en utilisant des séries temporelles de LAI composées de quatre ou cinq images acquises au cours de la saison végétative, alors que les paramètres extraits des données radars acquises en bande C, que ce soit en mode « Quad-pol » ou en mode « Ultra-fin », n'apportent pas d'informations sur la caractérisation des prairies.

Sur le plan méthodologique, la partie innovante vient de la prise en compte explicite de la nature temporelle des données dans certaines méthodes de classification [Dusseux *et al.* 2014b]. En effet, les pratiques agricoles étant évolutives au cours du temps, s'appuyer sur la comparaison directe des profils temporels apparaît comme une idée intéressante pour mieux les détecter. Cependant, en raison d'une part de la complexité des séries temporelles de paramètres issus des images optiques et radars, et d'autre part des décalages temporels susceptibles d'apparaître (entre deux prairies, les pratiques peuvent être identiques mais décalées dans le temps), se baser sur une comparaison des valeurs de paramètres pris indépendamment sur chaque image pour comparer les profils n'est pas une solution optimale. Ainsi, nous avons utilisé des métriques « élastiques » cherchant à mettre en correspondance

des formes de profils similaires. Avec de telles métriques, les résultats obtenus en termes de qualité de classification des pratiques agricoles furent nettement plus satisfaisants qu'avec l'utilisation de métriques standards.

Plusieurs perspectives peuvent être dégagées à partir de ce travail, tant sur le plan thématique que sur le plan méthodologique.

D'un point de vue thématique, les informations que nous pouvons d'ors et déjà extraire à partir des séries temporelles d'images à haute résolution spatiale et que nous pourrions dans un avenir proche produire en exploitant les images des futurs capteurs *Ven $\mu$ s* et Sentinel, constituent et constitueront une aide à la gestion des prairies, tant à l'échelle de l'exploitation agricole qu'à une échelle territoriale :

Les données de télédétection pourraient être utilisées de façon opérationnelle pour aider les agriculteurs à gérer leurs prairies à l'échelle de leur exploitation. En effet, les résultats que nous avons obtenus dans cette thèse permettent d'envisager l'estimation du stock d'herbe disponible à l'échelle d'une exploitation en temps réel. Des données de type Sentinel pourraient être utilisées pour estimer la biomasse tous les 5 à 10 jours, ce qui faciliterait la gestion des prairies. Cette information pourrait aussi être intégrée dans une plateforme telle que FARMSTAR qui est dédiée aujourd'hui exclusivement à la gestion des cultures ou dans des modèles de cultures tels que STICS [Brisson *et al.* 2003] afin d'améliorer l'estimation de la production des prairies en fonction des conditions climatiques par exemple.

Les données de télédétection pourraient être utilisées de façon opérationnelle pour aider les gestionnaires à prendre des décisions sur la gestion des prairies au sein des systèmes de production à l'échelle d'un bassin versant ou d'une région agricole. En effet, les informations dérivées des données de télédétection telles que des variables biophysiques, des métriques temporelles obtenues à partir de ces dernières ou les cartes des successions culturales peuvent être utilisées dans les modèles de croissance des plantes, des modèles de reconnaissance des patrons de successions culturales ou des modèles de gestion de pratiques agricoles. Elles peuvent être soit directement intégrées dans ces modèles comme variables d'entrées, ou utilisées pour calibrer et/ou valider ces modèles. Les informations dérivées des données de télédétection que nous avons traitées sur le bassin versant du Yar ont d'ors et déjà été exploitées dans les modèles ArpentAge [Lazrak 2012], CASIMOD'N [Moreau *et al.* 2012] et PaturMata (pour ce dernier un article a été soumis : P. Dusseux, Y. Zhao, M.O. Cordier, T. Corpetti, C. Gascuel-Odoux and L. Hubert-Moy, 2014. *Simulation of grassland management at the farm scale using the PaturMata model*, Agronomy for Sustainable Development). Plus généralement, les informations que nous récupérons sur les prairies mais aussi sur le reste du territoire à partir des séries temporelles d'images à haute résolution spatiale peuvent être utilisées dans des modèles de prédiction des changements d'occupation et d'utilisation des sols en relation avec le changement climatique [Houet *et al.* 2010] ou dans des modèles physiques de fonctionnement des surfaces, mettant en œuvre des processus tels que le stockage de carbone, ou le ruissellement.

D'un point de vue méthodologique, l'ensemble des prétraitements et des traitements qui ont été réalisés sur des séries temporelles d'images satellites à haute résolution spatiale SPOT, Landsat et Quickbird dans le domaine optique et Radarsat-2 dans les hyperfréquences sont reproductibles et applicables à d'autres types d'images à haute résolution spatiale telles que TerraSAR-X et aux futures séries d'images qui seront produites avec de nouveaux capteurs tels que *Ven $\mu$ s* et Sentinel 1 et 2 :

Dans cette thèse, le LAI a été dérivé des images satellites en utilisant un modèle de transfert radiatif couplé, PROSAIL, qui combine un modèle de transfert radiatif des feuilles, PROSPECT, avec un modèle de transfert radiatif des couverts (SAIL) [Jacquemoud *et al.* 2009, Darvishzadeh *et al.* 2008]. Dans le contexte de la préparation des futurs capteurs à haute résolutions spatiale et temporelle, plusieurs études récentes ont exploré le potentiel et les limites des bandes spectrales simulées de ces capteurs pour estimer le LAI des couverts végétaux, en utilisant soit PROSAIL [Richter *et al.* 2012, Richter & Atzberger 2012, Richter *et al.* 2011] soit directement les bandes spectrales situées dans le red-edge [Jesus *et al.* 2011, Herrmann *et al.* 2011]. Ces études confirment que l'utilisation d'un modèle de transfert radiatif est nécessaire pour estimer correctement le LAI. Ainsi, l'approche développée dans cette thèse à partir de données de type SPOT, Landsat et Quickbird pourra être directement appliquée en l'adaptant aux futures séries de données. Une partie des méthodes de classification utilisées dans cette thèse intègrent une métrique temporelle pour comparer et classer des séries temporelles hétérogènes et de tailles différentes. L'utilisation de mesures adaptées à la comparaison de séries temporelles offre l'avantage de comparer les profils en prenant en compte l'aspect temporel et pouvant présenter des modèles fortement asynchrones, contrairement à des critères de comparaison usuels comme la distance euclidienne. Elles pourront donc être appliquées sur les images des futures séries de données, dont une partie des images sera inexploitable en totalité ou partiellement, notamment en raison de la présence de la couverture nuageuse. De plus, ces métriques temporelles peuvent être intégrées dans toutes les techniques de classification, supervisées ou non.

Dans cette thèse, nous avons évalué la capacité de données acquises par Radarsat-2 dans deux modes d'acquisition différents, le mode « Quad-pol » et le mode « Ultra-fin » avec une seule polarisation. Il serait intéressant d'appliquer la méthodologie mise en œuvre dans la thèse à des données TerraSAR-X. En effet, dotées d'une meilleure résolution spatiale (d'un ordre métrique) et d'une longueur d'onde plus faible qui pénètre moins dans le couvert végétal, elles paraissent bien adaptées à l'identification des modes de gestion des prairies.

Plus généralement, il est important de souligner que même si la méthodologie développée dans cette thèse a été appliquée pour identifier et à caractériser les prairies, elle peut être reproduite sur d'autres types d'occupation des sols, pour suivre les pratiques culturales et le développement phénologique des plantes.

# Bibliographie

- [Andres *et al.* 1994] L. Andres, W.A. Salas et D. Skole. *Fourier analysis of multi-temporal AVHRR data applied to a land cover classification*. International Journal of Remote Sensing, vol. 15, no. 5, pages 1115–1121, 1994. (33)
- [Arrouays *et al.* 2001] D. Arrouays, W. Deslais et V. Badaeu. *The carbon content of topsoil and its geographical distribution in France*. Soil Use and Management, vol. 17, no. 1, pages 7–11, 2001. (99)
- [Arvalis 2011] Arvalis. *Méthode Herbo-LIS®*. Institut du Végétal, 2011. (73, 75)
- [Arvor *et al.* 2011] D. Arvor, M. Jonathan, M. S. P. Meirelles, V. Dubreuil et L. Durieux. *Classification of MODIS EVI time series for crop mapping in the state of Mato Grosso, Brazil*. International Journal of Remote Sensing, vol. 32, no. 22, pages 7847–7871, 2011. (32)
- [Asam *et al.* 2013] S. Asam, H. Fabritius, D. Klein, C. Conrad et S. Dech. *Derivation of leaf area index for grassland within alpine upland using multi-temporal RapidEye data*. International Journal of Remote Sensing, vol. 34, no. 23, pages 8628–8652, 2013. (50, 68)
- [ASD 2000] ASD. *FieldSpec 3 Portable Spectroradiometer User's Guide*. CO : Analytical Spectral Devices, 2000. (56)
- [Atzberger 2013] C. Atzberger. *Advances in Remote Sensing of Agriculture : Context Description, Existing Operational Monitoring Systems and Major Information Needs*. Remote Sensing, vol. 5, no. 2, pages 949–981, 2013. (xii)
- [Bacour & Jacquemoud 2001] C. Bacour et S. Jacquemoud. *Coupling spectral and bidirectional information to estimate canopy biophysical parameters by model inversion*. In Proc. International Workshop on Spectroscopy Application in Precision Farming (IWSAPF), Freising-Weihenstephan (Germany), pages 74–77, 2001. (49, 254)
- [Bacour *et al.* 2003] C. Bacour, F. Baret et G. Derive. *CYCLOPES algorithmic development for estimating biophysical products from large swath sensors*. In Proceedings of IEEE International Geoscience and Remote Sensing Symposium, IGARSS '03, vol. 6, pages 3902–3904, 2003. (49, 50, 254)
- [Bacour *et al.* 2006] C. Bacour, F. Baret, D. Béal, M. Weiss et K. Pavageau. *Neural network estimation of LAI, fAPAR, fCover and LAI\*Cab, from top of canopy MERIS reflectance data : Principles and validation*. Remote Sensing of Environment, vol. 105, no. 4, pages 313–325, 2006. (24, 50)
- [Baghdadi *et al.* 2001] N. Baghdadi, M. Bernier, R. Gauthier et I. Neeson. *Evaluation of C-band SAR data for wetlands mapping*. International Journal of Remote Sensing, vol. 22, no. 1, pages 71–88, 2001. (25, 27, 51)
- [Baghdadi *et al.* 2009] N. Baghdadi, N. Boyer, P. Todoroff, M. El Hajj et A. Bégué. *Potential of SAR sensors TerraSAR-X, ASAR/ENVISAT and PALSAR/ALOS for monitoring sugarcane crops on Reunion Island*. Remote Sensing of Environment, vol. 113, no. 8, pages 1724–1738, 2009. (xiii, 18, 99, 119, 121, 123)

- [Bahlmann *et al.* 2002] C. Bahlmann, B. Haasdonk et H. Burkhardt. *On-Line Handwriting Recognition with Support Vector Machines - A Kernel Approach*. In Proceedings of the Eighth International Workshop on Frontiers in Handwriting Recognition, IWFHR '02, Washington, DC, USA, pages 49–54, 2002. (148)
- [Bannari *et al.* 1995] A. Bannari, D. Morin, F. Bonn et A. R. Huete. *A review of vegetation indices*. Remote Sensing Reviews, vol. 13, no. 1-2, pages 95–120, 1995. (21)
- [Baret & Guyot 1991] F. Baret et G. Guyot. *Potentials and limits of vegetation indices for LAI and APAR assessment*. Remote Sensing of Environment, vol. 35, pages 161–173, 1991. (21, 23, 74)
- [Baret *et al.* 1989] F. Baret, G. Guyot et D.J. Major. *TSAVI : a vegetation index which minimizes soil brightness effects on LAI and APAR estimation*. In Proceedings of the 12th Canadian Symposium on Remote Sensing and IGARSS'89, vol. 3, Cairo, Egypt, pages 1355–1358, 1989. (21, 23, 74, 87)
- [Baret *et al.* 1992] F. Baret, S. Jacquemoud, G. Guyot et C. Leprieur. *Modeled analysis of the biophysical nature of spectral shifts and comparison with information content of broad bands*. Remote Sensing of Environment, vol. 41, no. 2-3, pages 133–142, 1992. (24)
- [Baret *et al.* 2007] F. Baret, O. Hagolle, B. Geiger, P. Bicheron, B. Miras, M. Huc, B. Berthelot, F. Niño, M. Weiss, O. Samain, J. L. Roujean et M. Leroy. *LAI, fAPAR and fCover CYCLOPES global products derived from VEGETATION : Part 1 : Principles of the algorithm*. Remote Sensing of Environment, vol. 110, no. 3, pages 275–286, 2007. (50)
- [Baret *et al.* 2010] F. Baret, B. de Solan, R. Lopez-Lozano, K. Ma et M. Weiss. *GAI estimates of row crops from downward looking digital photos taken perpendicular to rows at 57.5° zenith angle : Theoretical considerations based on 3D architecture models and application to wheat crops*. Agricultural and Forest Meteorology, vol. 150, no. 11, pages 1393–1401, 2010. (60)
- [Batáry *et al.* 2007] P. Batáry, A. Báldi et S. Erdős. *Grassland versus non-grassland bird abundance and diversity in managed grasslands : local, landscape and regional scale effects*. Biodiversity and Conservation, vol. 16, pages 871–881, 2007. (99)
- [Benoit *et al.* 1988] M. Benoit, C.M. Girard et E. De Vaubernier. *Comparaison du comportement spectral de prairies permanentes en Lorraine avec leur type d'utilisation*. Agronomie, vol. 8, no. 3, pages 265–272, 1988. (7, 20, 21)
- [Benoit *et al.* 1989] M. Benoit, M.C. Girard et E. De Vaubernier. *Utilisation de la télédétection pour reconnaître et cartographier les types de prairies permanentes*. In 16<sup>e</sup> Congrès International des Herbages, Nice, France, pages 1385–1386, 1989. (xii, 16, 21)
- [Betbeder *et al.* 2013] J. Betbeder, S. Rapinel, T. Corpetti, E. Pottier, S. Corgne et L. Hubert-Moy. *Multi-temporal classification of TerraSAR-X data for wetland vegetation mapping*. In Proceedings of SPIE 8887, Remote Sensing for Agriculture, Ecosystems, and Hydrology XV, page 88871B, 2013. (119)
- [Beurs & Henebry 2010] K. M. de Beurs et G M Henebry. *A land surface phenology assessment of the northern polar regions using MODIS reflectance time series*. Canadian Journal of Remote Sensing, vol. 36, no. S1, pages S87–S110, 2010. (20)
- [Blaes *et al.* 2005] X. Blaes, L. Vanhalle et P. Defourny. *Efficiency of crop identification based on optical and SAR image time series*. Remote Sensing of Environment, vol. 96, no. 3-4, pages 352–365, 2005. (xiii)
- [Blüthgen *et al.* 2012] N. Blüthgen, C. F. Dormann, D. Prati, V. H. Klaus, T. Kleinebecker, N. Hölzel, F. Alt, S. Boch, S. Gockel, A. Hemp, J. Müller, J. Nieschulze, S. C. Renner, I. Schöning, U. Schumacher, S. A. Socher, K. Wells, K. Birkhofer, F. Buscot, Y. Oelmann, C. Rothenwöhrer, C. Scherber, T. Tschardtke, C. N. Weiner, M. Fischer, E. K.V. Kalko, K. E. Linsenmair, E.D

- Schulze et W. W. Weisser. *A quantitative index of land-use intensity in grasslands : Integrating mowing, grazing and fertilization*. Basic and Applied Ecology, vol. 13, no. 3, pages 207–220, 2012. (3)
- [Boschetti et al. 2007] M. Boschetti, S. Bocchi et P. A. Brivio. *Assessment of pasture production in the Italian Alps using spectrometric and remote sensing information*. Agriculture, Ecosystems & Environment, vol. 118, no. 1–4, pages 267–272, 2007. (56)
- [Bouman 1991] B. A. M. Bouman. *Crop parameter estimation from ground-based x-band (3-cm wave) radar backscattering data*. Remote Sensing of Environment, vol. 37, no. 3, pages 193–205, 1991. (99)
- [Brisco et al. 2011] B. Brisco, M. Kapfer, T. Hirose, B. Tedford et J. Liu. *Evaluation of C-band polarization diversity and polarimetry for wetland mapping*. Canadian Journal of Remote Sensing, vol. 37, no. 1, pages 82–92, 2011. (27, 116)
- [Brisson et al. 2003] N. Brisson, C. Gary, E. Justes, R. Roche, B. Mary, D. Ripoche, D. Zimmer, J. Sierra, P. Bertuzzi, P. Burger, F. Bussi ere, Y.M. Cabidoche, P. Cellier, P. Debaeke, J.P. Gaudill ere, C. H enault, F. Maraux, B. Seguin et H. Sinoquet. *An overview of the crop model stics*. European Journal of Agronomy, vol. 18, no. 3–4, pages 309–332, 2003. (95, 169)
- [Brown et al. 2013] J. C. Brown, J. H. Kastens, A. C. Coutinho, D. de Castro Victoria et C. R. Bishop. *Classifying multiyear agricultural land use data from Mato Grosso using time-series MODIS vegetation index data*. Remote Sensing of Environment, vol. 130, pages 39–50, 2013. (20, 32)
- [Br user et al. 2014] K. Br user, H. Feilhauer, A. Linst adter, J. Schellberg, R. J. Oomen, J. C. Ruppert et F. Ewert. *Discrimination and characterization of management systems in semi-arid rangelands of South Africa using RapidEye time series*. International Journal of Remote Sensing, vol. 35, no. 5, pages 1653–1673, 2014. (68)
- [Brunschwig et al. 2006] G. Brunschwig, E. Josien et C. Bernhard. *Contraintes g eographiques et modes d’utilisation des parcelles en  levage bovin laitier et allaitant*. Fourrages, vol. 185, pages 83–95, 2006. (8)
- [Bruzzone & Prieto 2000] L. Bruzzone et D.F. Prieto. *Automatic analysis of the difference image for unsupervised change detection*. IEEE Transactions on Geoscience and Remote Sensing, vol. 38, no. 3, pages 1171–1182, 2000. (33)
- [Bruzzone & Serpico 2000] L. Bruzzone et S. B. Serpico. *A technique for feature selection in multiclass problems*. International Journal of Remote Sensing, vol. 21, no. 3, pages 549–563, 2000. (31)
- [Bruzzone et al. 1999] L. Bruzzone, D.F. Prieto et S.B. Serpico. *A neural-statistical approach to multitemporal and multisource remote-sensing image classification*. IEEE Transactions on Geoscience and Remote Sensing, vol. 37, no. 3, pages 1350–1359, 1999. (32)
- [Bsaibes et al. 2009] A. Bsaibes, D. Courault, F. Baret, M. Weiss, A. Olioso, F. Jacob, O. Hagolle, O. Marloie, N. Bertrand, V. Desfond et F. Kzemipour. *Albedo and LAI estimates from FORMOSAT-2 data for crop monitoring*. Remote Sensing of Environment, vol. 113, no. 4, pages 716–729, 2009. (50, 68)
- [Buckley & Smith 2010] J.R. Buckley et A.M. Smith. *Monitoring grasslands with radarsat 2 quad-pol imagery*. In Proceedings of IEEE International Geoscience and Remote Sensing Symposium, IGARSS ’10, Honolulu, USA, pages 3090–3093, 2010. (51, 110, 123)
- [Buckley 2004] J. R. Buckley. *Enhanced classification of prairie landscapes using simulated RADARSAT-2 imagery*. Canadian Journal of Remote Sensing, vol. 30, no. 3, pages 510–516, 2004. (27)
- [Camps-Valls et al. 2006] G. Camps-Valls, L. Gomez-Chova, J. Munoz-Mari, J. Vila-Frances et J. Calpe-Maravilla. *Composite kernels for hyperspectral image classification*. IEEE Geoscience and Remote Sensing Letters, vol. 3, no. 1, pages 93–97, 2006. (32)

- [Carlson & Ripley 1997] T. N. Carlson et D. A. Ripley. *On the relation between NDVI, fractional vegetation cover, and leaf area index*. *Remote Sensing of Environment*, vol. 62, no. 3, pages 241–252, 1997. (23, 73, 83, 89)
- [Carrère 2012] P. Carrère. *Concilier les services rendus par les prairies pour assurer la durabilité des systèmes d'élevage herbagers*. *Fourrages*, vol. 211, pages 213–218, 2012. (4)
- [Celik & Ma 2011] T. Celik et K.K. Ma. *Multitemporal Image Change Detection Using Undecimated Discrete Wavelet Transform and Active Contours*. *IEEE Transactions on Geoscience and Remote Sensing*, vol. 49, no. 2, pages 706–716, 2011. (33)
- [Chen & Black 1991] J. M. Chen et T. A. Black. *Measuring leaf area index of plant canopies with branch architecture*. *Agricultural and forest meteorology*, vol. 57, no. 1-3, pages 1–12, 1991. (50)
- [Cingolani et al. 2004] A. M. Cingolani, D. Renison, M. R. Zak et M. R. Cabido. *Mapping vegetation in a heterogeneous mountain rangeland using landsat data : an alternative method to define and classify land-cover units*. *Remote Sensing of Environment*, vol. 92, no. 1, pages 84–97, 2004. (20)
- [Claverie et al. 2012] M. Claverie, V. Demarez, B. Duchemin, O. Hagolle, D. Ducrot, C. Marais-Sicre, J.F. Dejoux, M. Huc, P. Keravec, P. Béziat, R. Fieuzal, E. Ceschia et G. Dedieu. *Maize and sunflower biomass estimation in southwest France using high spatial and temporal resolution remote sensing data*. *Remote Sensing of Environment*, vol. 124, pages 844–857, 2012. (47, 60)
- [Claverie et al. 2013] M. Claverie, E. F. Vermote, M. Weiss, F. Baret, O. Hagolle et V. Demarez. *Validation of coarse spatial resolution LAI and FAPAR time series over cropland in southwest France*. *Remote Sensing of Environment*, vol. 139, pages 216–230, 2013. (50, 68)
- [Cloude & Pottier 1997] S.R. Cloude et E. Pottier. *An entropy based classification scheme for land applications of polarimetric SAR*. *IEEE Transactions on Geoscience and Remote Sensing*, vol. 35, no. 1, pages 68–78, 1997. (27, 52, 116, 121, 157)
- [Cohen 1960] J. Cohen. *A coefficient of agreement for nominales scales*. *Educational and Psychological Measurement*, vol. 20, no. 1, pages 37–46, 1960. (55)
- [Cole et al. 2006] L. Cole, M. A. Bradford, P. J.A. Shaw et R. D. Bardgett. *The abundance, richness and functional role of soil meso- and macrofauna in temperate grassland—A case study*. *Applied Soil Ecology*, vol. 33, no. 2, pages 186–198, 2006. (3)
- [Congalton 1991] R. G. Congalton. *A review of assessing the accuracy of classifications of remotely sensed data*. *Remote Sensing of Environment*, vol. 37, pages 35–46, 1991. (55, 82, 117, 158)
- [Corgne 2004] S. Corgne. *Modélisation prédictive de l'occupation des sols en contexte agricole intensif : application à la couverture hivernale des sols en Bretagne*. Thèse de géographie, Université Rennes 2, 230p., 2004. (37)
- [Cortes & Vapnik 1995] C. Cortes et V. Vapnik. *Support-Vector Networks*. *Machine Learning*, vol. 20, no. 3, pages 273–297, 1995. (54)
- [Cover & Hart 1967a] T. Cover et P. Hart. *Nearest neighbor pattern classification*. *IEEE Transactions on Information Theory*, vol. 13, no. 1, pages 21–27, 1967. (53)
- [Cover & Hart 1967b] T.M. Cover et P.E. Hart. *Nearest neighbor pattern classification*. *IEEE Transactions on Information Theory*, vol. 13, no. 1, pages 21–27, 1967. (82)
- [Cuturi et al. 2007] M. Cuturi, J. Vert, O. Birkenes et T. Matsui. *A Kernel for Time Series Based on Global Alignments*. In *IEEE International Conference on Acoustics, Speech and Signal Processing, ICASSP'07*, vol. 2, pages II–413–II–416, 2007. (148, 149)

- [Cuturi 2011] M. Cuturi. *Fast Global Alignment Kernels*. In Proceedings of the 28th International Conference on Machine Learning, ICML'11, New York, NY, USA, ACM.Lise Getoor et Tobias Scheffer, éditeurs, pages 929–936, 2011. (148)
- [Darvishzadeh *et al.* 2008] R. Darvishzadeh, A. Skidmore, M. Schlerf et C. Atzberger. *Inversion of a radiative transfer model for estimating vegetation LAI and chlorophyll in a heterogeneous grassland*. *Remote Sensing of Environment*, vol. 112, no. 5, pages 2592–2604, 2008. (50, 170)
- [Darvishzadeh *et al.* 2011] R. Darvishzadeh, C. Atzberger, A. Skidmore et M. Schlerf. *Mapping grassland leaf area index with airborne hyperspectral imagery : A comparison study of statistical approaches and inversion of radiative transfer models*. *ISPRS Journal of Photogrammetry and Remote Sensing*, vol. 66, no. 6, pages 894–906, 2011. (23)
- [Debinski *et al.* 1999] D. M. Debinski, K. Kindscher et M. E. Jakubauskas. *A remote sensing and GIS-based model of habitats and biodiversity in the Greater Yellowstone Ecosystem*. *International Journal of Remote Sensing*, vol. 20, no. 17, pages 3281–3291, 1999. (21)
- [Delaby *et al.* 2001] L. Delaby, J.L. Peyraud et P. Faverdin. *Patur' IN : le pâturage des vaches laitières assiste par ordinateur*. *Fourrages*, vol. 167, no. 2, pages 385–398, 2001. (xii, 73, 75)
- [Deller *et al.* 1993] J. R. Deller, J.G. Proakis et J.H. Hansen. *Discrete time processing of speech signals*. Prentice Hall PTR, Upper Saddle River, NJ, USA, 1st édition, 1993. (33)
- [Demarez *et al.* 2008] V. Demarez, S. Duthoit, F. Baret, M. Weiss et G. Dedieu. *Estimation of leaf area and clumping indexes of crops with hemispherical photographs*. *Agricultural and Forest Meteorology*, vol. 148, no. 4, pages 644–655, 2008. (60)
- [Díaz & Blackburn 2003] B. M. Díaz et G. A. Blackburn. *Remote sensing of mangrove biophysical properties : Evidence from a laboratory simulation of the possible effects of background variation on spectral vegetation indices*. *International Journal of Remote Sensing*, vol. 24, no. 1, pages 53–73, 2003. (23, 74, 83, 89)
- [Berndt & Clifford 1994] D.J. Berndt et J. Clifford. *Using Dynamic Time Warping to Find Patterns in Time Series*. pages 359–370, 1994. (33)
- [Doraiswamy *et al.* 2007] P.C. Doraiswamy, A.J. Stern et B. Akhmedov. *Crop classification in the U.S. Corn Belt using MODIS imagery*. In IEEE International Geoscience and Remote Sensing Symposium, IGARSS'07, pages 809–812, 2007. (20, 21)
- [Dorigo *et al.* 2007] W.A. Dorigo, R. Zurita-Milla, A.J.W. de Wit, J. Brazile, R. Singh et M.E. Schaepman. *A review on reflective remote sensing and data assimilation techniques for enhanced agroecosystem modeling*. *International Journal of Applied Earth Observation and Geoinformation*, vol. 9, no. 2, pages 165–193, 2007. (21)
- [Dusseux *et al.* 2014a] P. Dusseux, T. Corpetti, L. Hubert-Moy et S. Corgne. *Combined Use of Multi-Temporal Optical and Radar Satellite Images for Grassland Monitoring*. *Remote Sensing*, vol. 6, pages 6163–6182, 2014. (168)
- [Dusseux *et al.* 2014b] P. Dusseux, X. Gong, L. Hubert-Moy et T. Corpetti. *Identification of grassland management practices from leaf area index time series*. *Journal of Applied Remote Sensing*, vol. 8, no. 2, pages 083559, 2014. (168)
- [Dusseux *et al.* 2014c] P. Dusseux, F. Vertès, T. Corpetti, S. Corgne et L. Hubert-Moy. *Agricultural practices in grasslands detected by spatial remote sensing*. *Environmental Monitoring and Assessment*, 2014. (167)
- [Duveiller & Defourny 2010] G. Duveiller et P. Defourny. *A conceptual framework to define the spatial resolution requirements for agricultural monitoring using remote sensing*. *Remote Sensing of Environment*, vol. 114, no. 11, pages 2637–2650, 2010. (16)

- [Duveiller *et al.* 2011] G. Duveiller, M. Weiss, F. Baret et P. Defourny. *Retrieving wheat Green Area Index during the growing season from optical time series measurements based on neural network radiative transfer inversion*. *Remote Sensing of Environment*, vol. 115, no. 3, pages 887–896, 2011. (50)
- [Edirisinghe *et al.* 2011] A. Edirisinghe, M. J. Hill, G. E. Donald et M. Hyder. *Quantitative mapping of pasture biomass using satellite imagery*. *International Journal of Remote Sensing*, vol. 32, no. 10, pages 2699–2724, 2011. (23, 71, 73, 79, 83, 89)
- [El Hajj *et al.* 2009] M. El Hajj, A. Bégué, S. Guillaume et J.-F. Martiné. *Integrating SPOT-5 time series, crop growth modeling and expert knowledge for monitoring agricultural practices — The case of sugarcane harvest on Reunion Island*. *Remote Sensing of Environment*, vol. 113, no. 10, pages 2052–2061, 2009. (xiii, 47)
- [Esch *et al.* 2014] T. Esch, A. Metz, M. Marconcini et M. Keil. *Combined use of multi-seasonal high and medium resolution satellite imagery for parcel-related mapping of cropland and grassland*. *International Journal of Applied Earth Observation and Geoinformation*, vol. 28, pages 230–237, 2014. (32)
- [Feilhauer *et al.* 2013] H. Feilhauer, F. Thonfeld, U. Faude, K. S. He, D. Rocchini et S. Schmidlein. *Assessing floristic composition with multispectral sensors—A comparison based on monotemporal and multiseasonal field spectra*. *International Journal of Applied Earth Observation and Geoinformation*, vol. 21, pages 218–229, 2013. (xii)
- [Feret *et al.* 2008] J.-B. Feret, C. François, G. P. Asner, A. A. Gitelson, R. E. Martin, L. P.R. Bidel, S. L. Ustin, G. le Maire et S. Jacquemoud. *PROSPECT-4 and 5 : Advances in the leaf optical properties model separating photosynthetic pigments*. *Remote Sensing of Environment*, vol. 112, no. 6, pages 3030–3043, 2008. (50)
- [Foerster *et al.* 2012] S. Foerster, K. Kaden, M. Foerster et S. Itzerott. *Crop type mapping using spectral-temporal profiles and phenological information*. *Computers and Electronics in Agriculture*, vol. 89, pages 30–40, 2012. (xii)
- [Fontana *et al.* 2008] F. Fontana, C. Rixen, T. Jonas, G. Aberegg et S. Wunderle. *Alpine Grassland Phenology as Seen in AVHRR, VEGETATION, and MODIS NDVI Time Series - a Comparison with In Situ Measurements*. *Sensors*, vol. 8, no. 4, pages 2833–2853, 2008. (23, 58)
- [Franke *et al.* 2006] J. Franke, V. Heinzel et G. Menz. *Assessment of NDVI- Differences Caused by Sensor Specific Relative Spectral Response Functions*. In *Proceedings of IEEE International Conference on Geoscience and Remote Sensing Symposium, IGARSS'06*, pages 1138–1141, 2006. (23, 74)
- [Franke *et al.* 2012] J. Franke, V. Keuck et F. Siegert. *Assessment of grassland use intensity by remote sensing to support conservation schemes*. *Journal for Nature Conservation*, vol. 20, no. 3, pages 125–134, 2012. (xii)
- [Freeman & Durden 1998] A. Freeman et S.L. Durden. *A three-component scattering model for polarimetric SAR data*. *IEEE Transactions on Geoscience and Remote Sensing*, vol. 36, no. 3, pages 963–973, 1998. (27, 29, 52)
- [Freeman *et al.* 1994] A. Freeman, J. Villasenor, J.D. Klein, P. Hoogeboom et J. Groot. *On the use of multi-frequency and polarimetric radar backscatter features for classification of agricultural crops*. *International Journal of Remote Sensing*, vol. 15, no. 9, pages 1799–1812, 1994. (51, 116, 122, 123, 157)
- [Friedl *et al.* 1994] M.A. Friedl, J. Michaelsen, F. W. Davis, H. Walker et D. S. Schimel. *Estimating grassland biomass and Leaf Area Index using ground and satellite data*. *International Journal of Remote Sensing*, vol. 15, pages 1401–1420, 1994. (50, 68)

- [Gambarova 2010] Y. M. Gambarova. *Remote Sensing and GIS as an Advance Space Technologies for Rare Vegetation Monitoring in Gobustan State National Park, Azerbaijan*. Journal of Geographic Information System, vol. 02, no. 02, pages 93–99, 2010. (116)
- [Gao et al. 2012] F. Gao, M. C. Anderson, W. P. Kustas et Y. Wang. *Simple method for retrieving leaf area index from Landsat using MODIS leaf area index products as reference*. Journal of Applied Remote Sensing, vol. 6, no. 1, page 063554, 2012. (23)
- [Gao et al. 2013] S. Gao, Z. Niu, N. Huang et X. Hou. *Estimating the Leaf Area Index, height and biomass of maize using HJ-1 and RADARSAT-2*. International Journal of Applied Earth Observation and Geoinformation, vol. 24, pages 1–8, 2013. (99, 115)
- [García-Feced et al. 2014] C. García-Feced, C. J. Weissteiner, A. Baraldi, M. L. Paracchini, J. Maes, G. Zulian, M. Kempen, B. Elbersen et M. Pérez-Soba. *Semi-natural vegetation in agricultural land : European map and links to ecosystem service supply*. Agronomy for Sustainable Development, pages 1–11, 2014. (xi)
- [Gardi et al. 2002] C. Gardi, M. Tomaselli, V. Parisi, A. Petraglia et C. Santini. *Soil quality indicators and biodiversity in northern Italian permanent grasslands*. European Journal of Soil Biology, vol. 38, no. 1, pages 103–110, 2002. (3)
- [Garrigues et al. 2008] S. Garrigues, N. V. Shabanov, K. Swanson, J. T. Morisette, F. Baret et R. B. Myneni. *Intercomparison and sensitivity analysis of Leaf Area Index retrievals from LAI-2000, AccuPAR, and digital hemispherical photography over croplands*. Agricultural and Forest Meteorology, vol. 148, no. 8–9, pages 1193–1209, 2008. (60)
- [Gastellu-Etchegorry et al. 2008] J.-P. Gastellu-Etchegorry, Y. Auda, E. Martin, A. Brut, V. Demarez, E. Grau, J. Rubio, N. Benech, C. Suere, A. S. Pierre, A. Groussous, A. Belot, P. Henry, V. Bernat et G. Precheur. *DART : modèle physique 3D d’images de télédétection et du bilan radiatif de paysages urbains et naturels*. Revue Télédétection, vol. 8, no. 3, pages 159–167, 2008. (24)
- [Geerken et al. 2005] R. Geerken, B. Zaitchik et J. P. Evans. *Classifying rangeland vegetation type and coverage from NDVI time series using Fourier Filtered Cycle Similarity*. International Journal of Remote Sensing, vol. 26, no. 24, pages 5535–5554, 2005. (20)
- [Girard & Benoit 1990] M.M. Girard et M. Benoit. *Méthode de cartographie des prairies permanentes : application à la Lorraine sur des données SPOT*. C.R. Acad. Sci. Paris, vol. 310, pages 461–464, 1990. (xii, 16, 20)
- [Girard & Girard 1999] M.C. Girard et C.M. Girard. *Traitement des données de télédétection*. Paris, 1999. (11, 19)
- [Girard et al. 2001] N. Girard, S. Bellon, B. Hubert, S. Lardon, C.H. Moulin et P.L. Osty. *Categorising combinations of farmers’ land use practices : an approach based on examples of sheep farms in the south of France*. Agronomie, vol. 21, no. 5, pages 435–459, 2001. (7)
- [Gitelson et al. 2002] A. A. Gitelson, Y. J. Kaufman, R. Stark et D. Rundquist. *Novel algorithms for remote estimation of vegetation fraction*. Remote Sensing of Environment, vol. 80, no. 1, pages 76–87, 2002. (23, 74, 83, 89)
- [Gjertsen 2007] A. K. Gjertsen. *Accuracy of forest mapping based on Landsat TM data and a kNN-based method*. Remote Sensing of Environment, vol. 110, no. 4, pages 420–430, 2007. (53)
- [Glenn et al. 2008] E. P. Glenn, A. R. Huete, P. L. Nagler et S. G. Nelson. *Relationship Between Remotely-sensed Vegetation Indices, Canopy Attributes and Plant Physiological Processes : What Vegetation Indices Can and Cannot Tell Us About the Landscape*. Sensors, vol. 8, no. 4, pages 2136–2160, 2008. (23, 74, 83, 89)

- [Grant *et al.* 2012] K. M. Grant, D.L. Johnson, D. V. Hildebrand et D. R. Peddle. *Quantifying biomass production on rangeland in southern Alberta using SPOT imagery*. Canadian Journal of Remote Sensing, vol. 38, no. 06, pages 695–708, 2012. (47, 71)
- [Granval 2000] P. Granval. *Intérêt faunistique de la prairies permanente pâturée*. Fourrages, vol. 162, pages 157–167, 2000. (3)
- [Grenier 2003] J. Grenier. *Evolution de la flore et gestion des prairies*. Bulletin du Pôle Scientifique Bio du Massif Central, no. 1, pages 6–7, 2003. (8)
- [Griffith *et al.* 2001] J. A. Griffith, K. P. Price et E. A. Martinko. *A multivariate analysis of biophysical parameters of tallgrass prairie among land management practices and years*. Environmental monitoring and assessment, vol. 68, no. 3, pages 249–271, 2001. (92)
- [Gueret 2006] G. Gueret. *Guide des habitats naturels du Poitou-Charentes*. <http://www.poitou-charentes-nature.asso.fr>, 2006. (7, 8, 9)
- [Guo *et al.* 2000] X. Guo, K. P. Price et J. M. Stiles. *Biophysical and Spectral Characteristics of Cool- and Warm-Season Grasslands under Three Land Management Practices in Eastern Kansas*. Natural Resources Research, vol. 9, no. 4, pages 321–331, 2000. (50, 67, 68)
- [Guo 2004] X. Guo. *Measuring Spatial and Vertical Heterogeneity of Grasslands Using Remote Sensing Techniques*. Journal of Environmental Informatics, vol. 3, no. 1, pages 24–32, 2004. (20)
- [Haasdonk & Keysers 2002] B. Haasdonk et D. Keysers. *Tangent Distance Kernels for Support Vector Machines*. In Proceedings of the 16th ICPR, pages 864–868, 2002. (148)
- [Hajnsek *et al.* 2009] I. Hajnsek, T. Jagdhuber, H. Schon et K.P. Papathanassiou. *Potential of Estimating Soil Moisture Under Vegetation Cover by Means of PolSAR*. IEEE Transactions on Geoscience and Remote Sensing, vol. 47, no. 2, pages 442–454, 2009. (27)
- [Hao *et al.* 2014] P. Hao, L. Wang, Z. Niu, A. Aablikim, N. Huang, S. Xu et F. Chen. *The Potential of Time Series Merged from Landsat-5 TM and HJ-1 CCD for Crop Classification : A Case Study for Bole and Manas Counties in Xinjiang, China*. Remote Sensing, vol. 6, no. 8, pages 7610–7631, 2014. (32, 53)
- [He *et al.* 2009] Y. He, X. Guo et J. F. Wilmshurst. *Reflectance measures of grassland biophysical structure*. International Journal of Remote Sensing, vol. 30, no. 10, pages 2509–2521, 2009. (68)
- [Henebry 1993] G. M. Henebry. *Detecting change in grasslands using measures of spatial dependence with landsat TM data*. Remote Sensing of Environment, vol. 46, no. 2, pages 223–234, 1993. (21, 23, 74)
- [Herold *et al.* 2001] M. Herold, C.C. Schmullius et I. Hajnsek. *Multifrequency and Polarimetric Radar Remote Sensing of Grassland – Geobiophysical and Landcover Parameter Retrieval with E-SAR Data*. In Decade of Trans-European Remote Sensing Cooperation. edited by M. F. Buchroithner, 2001. (26, 163)
- [Herrmann *et al.* 2011] I. Herrmann, A. Pimstein, A. Karnieli, Y. Cohen, V. Alchanatis et D. J. Bonfil. *LAI assessment of wheat and potato crops by VEN $\mu$ S and Sentinel-2 bands*. Remote Sensing of Environment, vol. 115, no. 8, pages 2141–2151, 2011. (170)
- [Hill & Donald 2003] M. J. Hill et G. E. Donald. *Estimating spatio-temporal patterns of agricultural productivity in fragmented landscapes using AVHRR NDVI time series*. Remote Sensing of Environment, vol. 84, no. 3, pages 367–384, 2003. (20)
- [Hill & Foody 1994] R. A. Hill et G. M. Foody. *Separability of tropical rain-forest types in the Tambopata-Candamo Reserved Zone, Peru*. International Journal of Remote Sensing, vol. 15, no. 13, pages 2687–2693, 1994. (116)

- [Hill *et al.* 1999a] M. J. Hill, G. E. Donald et P. J. Vickery. *Relating Radar Backscatter to Biophysical Properties of Temperate Perennial Grassland*. Remote Sensing of Environment, vol. 67, no. 1, pages 15–31, 1999. (26)
- [Hill *et al.* 1999b] M. J. Hill, P. J. Vickery, E.P. Furnival et G. E. Donald. *Pasture Land Cover in Eastern Australia from NOAA-AVHRR NDVI and Classified Landsat TM*. Remote Sensing of Environment, vol. 67, no. 1, pages 32–50, 1999. (20)
- [Hill *et al.* 2000] M. J. Hill, A. M. Smith et T. C. Foster. *Remote sensing of grassland with RADAR-SAT; Case studies from Australia and Canada : ADRO papers*. Canadian journal of remote sensing, vol. 26, no. 4, pages 285–296, 2000. (26, 110)
- [Hill *et al.* 2005] M.J. Hill, C.J. Ticehurst, J.S. Lee, M.R. Grunes, G.E. Donald et D. Henry. *Integration of optical and radar classifications for mapping pasture type in Western Australia*. IEEE Transactions on Geoscience and Remote Sensing, vol. 43, no. 7, pages 1665–1681, 2005. (xi, xii, xiii, 26, 27, 110)
- [Hill 2004] M.J. Hill. *Grazing Agriculture : Managed Pastures, Grassland and Rangeland*. In Remote Sensing for Natural Resource Management and Environmental Monitoring, Edited by S.L. Ustin. John Wiley and Sons Inc., New Jersey, pages 449–530. 2004. (xiii, 27)
- [Hill 2013] M. J. Hill. *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, vol. 137, pages 94–111, 2013. (xii, 68)
- [Homolová *et al.* 2013] L. Homolová, Z. Malenovský, J. G.P.W. Clevers, G. García-Santos et M. E. Schaepman. *Review of optical-based remote sensing for plant trait mapping*. Ecological Complexity, vol. 15, pages 1–16, 2013. (xiii, 47)
- [Houet *et al.* 2010] T. Houet, T. R. Loveland, L. Hubert-Moy, C. Gaucherel, D. Napton, C. A. Barnes et K. Sayler. *Exploring subtle land use and land cover changes : a framework for future landscape studies*. Landscape Ecology, vol. 25, no. 2, pages 249–266, 2010. (169)
- [Huang *et al.* 2002] C. Huang, L. S. Davis et J. R. G. Townshend. *An assessment of support vector machines for land cover classification*. International Journal of Remote Sensing, vol. 23, no. 4, pages 725–749, 2002. (53)
- [Hubert-Moy *et al.* 2003] L. Hubert-Moy, B. Clément, M. Lennon, T. Houet et E. Lefevre. *Study of wetlands using CASI hyperspectral images : Application to the valley floors of the Armorican Massif*. Photo-Interprétation, no. 6, pages 33–43, 2003. (21)
- [Hubert-Moy *et al.* 2005] L. Hubert-Moy, S. Corgne et B. Clément. *La détermination et le suivi de la couverture hivernale des sols au sein d'un bassin versant par télédétection : l'exemple du yar en bretagne, science update* In Savoirs et savoir-faire sur les bassins versants, pollution de l'eau et dynamique de restauration de sa qualité. Inra édition, 2005. (37)
- [Huete *et al.* 1985] A. R. Huete, R. D. Jackson et D. F. Post. *Spectral response of a plant canopy with different soil backgrounds*. Remote Sensing of Environment, vol. 17, no. 1, pages 37–53, 1985. (21, 23, 73, 74, 83, 89)
- [Huete *et al.* 1997] A. R. Huete, H. Q. Liu, K. Batchily et W. van Leeuwen. *A comparison of vegetation indices over a global set of TM images for EOS-MODIS*. Remote Sensing of Environment, vol. 59, no. 3, pages 440–451, 1997. (23, 73, 83, 89)
- [Huyghe *et al.* 2014] C. Huyghe, A. De Vlieghe, B. Van Gils et A. Peeters. *Grasslands and herbivore production in Europe and effects of common policies*. QUAE editions, 323p., 2014. (xi)
- [Huyghe 2009] C. Huyghe. *Evolution des prairies et cultures fourragères et de leurs modalités culturales et utilisation en France au cours des 50 dernières années*. Fourrages, vol. 200, pages 407–428, 2009. (3)

- [Inglada & Mercier 2007] J. Inglada et G. Mercier. *A New Statistical Similarity Measure for Change Detection in Multitemporal SAR Images and Its Extension to Multiscale Change Analysis*. IEEE Transactions on Geoscience and Remote Sensing, vol. 45, no. 5, pages 1432–1445, 2007. (33)
- [Inoue & Olioso 2006] Y. Inoue et A. Olioso. *Estimating the dynamics of ecosystem CO<sub>2</sub> flux and biomass production in agricultural fields on the basis of synergy between process models and remotely sensed signatures*. Journal of Geophysical Research : Atmospheres, vol. 111, no. D24, 2006. (68)
- [Inoue et al. 2002] Y. Inoue, T. Kurosu, H. Maeno, S. Uratsuka, T. Kozu, K. Dabrowska-Zielinska et J. Qi. *Season-long daily measurements of multifrequency (Ka, Ku, X, C, and L) and full-polarization backscatter signatures over paddy rice field and their relationship with biological variables*. Remote Sensing of Environment, vol. 81, no. 2–3, pages 194–204, 2002. (18)
- [Inoue et al. 2014] Y. Inoue, E. Sakaiya et C. Wang. *Capability of C-band backscattering coefficients from high-resolution satellite SAR sensors to assess biophysical variables in paddy rice*. Remote Sensing of Environment, vol. 140, pages 257–266, 2014. (99, 110, 119, 123)
- [Jacquemoud & Baret 1990] S. Jacquemoud et F. Baret. *PROSPECT : A model of leaf optical properties spectra*. Remote Sensing of Environment, vol. 34, no. 2, pages 75–91, 1990. (23, 74, 87)
- [Jacquemoud et al. 2006] S. Jacquemoud, W. Verhoef, F. Baret, P.J. Zarco-Tejada, G. P. Asner, C. François et S. L. Ustin. *PROSPECT + SAIL : 15 Years of Use for Land Surface Characterization*. In IEEE International Geoscience and Remote Sensing Symposium, IGARSS '06, vol. 2, Denver, USA, pages 1992–1995, 2006. (23, 24)
- [Jacquemoud et al. 2009] S. Jacquemoud, W. Verhoef, F. Baret, C. Bacour, P.J. Zarco-Tejada, G.P. Asner, C. François et S.L. Ustin. *PROSPECT + SAIL models : A review of use for vegetation characterization*. Remote Sensing of Environment, vol. 113, no. Supplement 1, pages S56–S66, 2009. (23, 24, 49, 50, 68, 74, 79, 99, 170)
- [Jannot 2007] P. Jannot. *L'importance des prairies par rapport à la qualité de l'eau : sa prise en compte dans les politiques publiques*. Fourrages, vol. 192, pages 387–398, 2007. (3, 10)
- [Jeangros & Amaudruz 2005] B. Jeangros et M. Amaudruz. *Dix ans d'observations sur la phénologie des prairies permanentes en Suisse Normande*. Revue Suisse Agric., vol. 5, no. 37, pages 201–209, 2005. (6)
- [Jensen et al. 2006] M. E. Jensen, J. P. Dibenedetto, J. A. Barber, C. Montagne et P. S. Bourgeron. *Spatial modeling of rangeland potential vegetation environments*. Journal of Range Management Archives, vol. 54, no. 5, pages 528–536, 2006. (21)
- [Jensen 2000] J. R. Jensen. *Remote sensing of the environment : an earth resource perspective*. Upper Saddle River, N.J. : Prentice Hall ; London : Prentice-Hall International, 2000. (20, 82, 86, 253)
- [Jérôme et al. 2014] E. Jérôme, Y. Beckers, B. Bodson, B. Heinesch, C. Moureaux et M. Aubinet. *Impact of grazing on carbon dioxide exchanges in an intensively managed Belgian grassland*. Agriculture, Ecosystems & Environment, vol. 194, pages 7–16, 2014. (99)
- [Jesus et al. 2011] J. Delegido, J. Verrelst, L. Alonso et J. Moreno . *Evaluation of Sentinel-2 red-edge bands for empirical estimation of green LAI and chlorophyll content*. Sensors (Basel, Switzerland), vol. 11, no. 7, pages 7063–7081, 2011. (170)
- [Ji & Peters 2007] L. Ji et A. J. Peters. *Performance evaluation of spectral vegetation indices using a statistical sensitivity function*. Remote Sensing of Environment, vol. 106, no. 1, pages 59–65, 2007. (23)
- [Jiang et al. 2006] Z. Jiang, A. R. Huete, J. Chen, Y. Chen, J. Li, G. Yan et X. Zhang. *Analysis of NDVI and scaled difference vegetation index retrievals of vegetation fraction*. Remote Sensing of Environment, vol. 101, no. 3, pages 366–378, 2006. (23, 74)

- [Jonckheere *et al.* 2004] I. Jonckheere, S. Fleck, K. Nackaerts, B. Muys, P. Coppin, M. Weiss et F. Baret. *Review of methods for in situ leaf area index determination : Part I. Theories, sensors and hemispherical photography*. Agricultural and Forest Meteorology, vol. 121, no. 1-2, pages 19–35, 2004. (58, 60)
- [Julea *et al.* 2008] A. Julea, N. Méger, E. Trouve et P. Bolon. *On Extracting Evolutions from Satellite Image Time Series*. In IEEE International Geoscience and Remote Sensing Symposium, IGARSS'08, vol. 5, pages V – 228–V – 231, 2008. (33)
- [Julea *et al.* 2011] A. Julea, N. Méger, P. Bolon, C. Rigotti, M-P Doin, C. Lasserre, E. Trouve et V.N. Lazarescu. *Unsupervised Spatiotemporal Mining of Satellite Image Time Series Using Grouped Frequent Sequential Patterns*. IEEE Transactions on Geoscience and Remote Sensing, vol. 49, no. 4, pages 1417–1430, 2011. (33)
- [Kallel *et al.* 2007] A. Kallel, S. Le Hégarat-Masclé, C. Ottlé et L. Hubert-Moy. *Determination of vegetation cover fraction by inversion of a four-parameter model based on isoline parametrization*. Remote Sensing of Environment, vol. 111, no. 4, pages 553–566, 2007. (24)
- [Kaufman & Remer 1994] Y.J. Kaufman et L.A. Remer. *Detection of forests using mid-IR reflectance : an application for aerosol studies*. IEEE Transactions on Geoscience and Remote Sensing, vol. 32, no. 3, pages 672–683, 1994. (23)
- [Keogh & Ratanamahatana 2005] E. Keogh et C. A. Ratanamahatana. *Exact Indexing of Dynamic Time Warping*. Knowl. Inf. Syst., vol. 7, no. 3, page 358–386, 2005. (33)
- [Kergomard 2000] C. Kergomard. *Pratique des corrections atmosphériques en télédétection : utilisation du logiciel 5S-PC*. Cybergeo : European Journal of Geography, 2000. (47)
- [Klimek *et al.* 2007] S. Klimek, A. Richter gen. Kemmermann, M. Hofmann et J. Isselstein. *Plant species richness and composition in managed grasslands : The relative importance of field management and environmental factors*. Biological Conservation, vol. 134, no. 4, pages 559–570, 2007. (xi)
- [Kohavi 1995] R. Kohavi. *A Study of Cross-validation and Bootstrap for Accuracy Estimation and Model Selection*. In Proceedings of the 14th International Joint Conference on Artificial Intelligence, IJCAI'95, San Francisco, CA, USA, Morgan Kaufmann Publishers Inc, Vol. 2, pages 1137–1143, 1995. (149)
- [Koppe *et al.* 2013] W. Koppe, M. L. Gnyp, C. Hütt, Y. Yao, Y. Miao, X. Chen et G. Bareth. *Rice monitoring with multi-temporal and dual-polarimetric TerraSAR-X data*. International Journal of Applied Earth Observation and Geoinformation, vol. 21, pages 568–576, 2013. (119)
- [Lam-Dao *et al.* 2009] N. Lam-Dao, T. Le Toan, A. Apan, A. Bouvet, F. Young et T. Le-Van. *Effects of changing rice cultural practices on C-band synthetic aperture radar backscatter using Envisat advanced synthetic aperture radar data in the Mekong River Delta*. Journal of Applied Remote Sensing, vol. 3, no. 1, page 033563, 2009. (121)
- [Lambin & Linderman 2006] E.F. Lambin et M. Linderman. *Time series of remote sensing data for land change science*. IEEE Transactions on Geoscience and Remote Sensing, vol. 44, no. 7, pages 1926–1928, 2006. (xii)
- [Lambin & Strahlers 1994] E. F. Lambin et A. H. Strahlers. *Change-vector analysis in multitemporal space : A tool to detect and categorize land-cover change processes using high temporal-resolution satellite data*. Remote Sensing of Environment, vol. 48, no. 2, pages 231–244, 1994. (33)
- [Lausch *et al.* 2013] A. Lausch, M. Pause, A. Schmidt, C. Salbach, S. Gwilym-Margianto et I. Merbach. *Temporal hyperspectral monitoring of chlorophyll, LAI, and water content of barley during a growing season*. Canadian Journal of Remote Sensing, pages 1–17, 2013. (21)

- [Lazrak 2012] E.G. Lazrak. *Fouille de données stochastique pour la compréhension des dynamiques temporelles et spatiales des territoires agricoles - Contribution à une agronomie numérique des territoires*. Thèse en sciences agronomiques, Université de Lorraine, 214p., 2012. (169)
- [Le Toan *et al.* 1992] T. Le Toan, A. Beaudoin, J. Riom et D. Guyon. *Relating forest biomass to SAR data*. IEEE Transactions on Geoscience and Remote Sensing, vol. 30, no. 2, pages 403–411, 1992. (99, 123)
- [Le Toan *et al.* 1997] T. Le Toan, F. Ribbes, L.F. Wang, N. Floury, K.H. Ding, J.A. Kong, M. Fujita et T. Kurosu. *Rice crop mapping and monitoring using ERS-1 data based on experiment and modeling results*. IEEE Transactions on Geoscience and Remote Sensing, vol. 35, no. 1, pages 41–56, 1997. (119)
- [Lecerf *et al.* 2008] R. Lecerf, L. Hubert-Moy, F. Baret, B. Abdel-Latif, T. Corpetti et H. Nicolas. *Estimating Biophysical Variables at 250m with reconstructed EOS/MODIS time series to monitor fragment landscapes*. In IEEE International Geoscience and Remote Sensing Symposium, IGARSS'08, Boston, USA, vol. 2, pages 954–957, 2008. (50, 74)
- [Lecerf 2008] R. Lecerf. *Suivi des changements d'occupation et d'utilisation des sols d'origine anthropique et climatique à l'échelle régionale par télédétection moyenne résolution (Application à la Bretagne)*. Thèse de géographie, Université Rennes 2, 326p., 2008. (xii, 16, 20, 24, 49, 50, 254)
- [Lee & Pottier 2009] J.-S. Lee et E. Pottier. *Polarimetric radar imaging : From basics to applications*. Taylor & Francis, 2009. (25, 27, 121)
- [Lee *et al.* 1999] J.-S. Lee, M.R. Grunes et G. De Grandi. *Polarimetric SAR speckle filtering and its implication for classification*. IEEE Transactions on Geoscience and Remote Sensing, vol. 37, no. 5, pages 2363–2373, 1999. (51)
- [Lefebvre *et al.* 2009] A. Lefebvre, T. Corpetti et L. Hubert-Moy. *A measure for change detection in very high resolution remote sensing images based on texture analysis*. In IEEE International Conference on Image Processing, ICIP'09, Cairo, Egypt, pages 1697–1700, 2009. (33)
- [Lefebvre 2011] A. Lefebvre. *Contribution de la texture pour l'analyse d'images à très haute résolution spatiale : application à la détection de changement en milieu périurbain*. Thèse de géographie, Université Rennes 2, 284p., 2011. (19)
- [Lei & Sun 2007] H. Lei et B. Sun. *A Study on the Dynamic Time Warping in Kernel Machines*. In Third International IEEE Conference on Signal-Image Technologies and Internet-Based System, SITIS'07, pages 839–845, 2007. (148)
- [Lemasson *et al.* 2008] C. Lemasson, P. Pierre et B. Osson. *Rénovation des prairies et sursemis : Comprendre, raisonner et choisir la méthode*. Fourrages, vol. 195, pages 315–330, 2008. (10)
- [Li *et al.* 2013] Z. Li, T. Huffman, B. McConkey et L. Townley-Smith. *Monitoring and modeling spatial and temporal patterns of grassland dynamics using time-series MODIS NDVI with climate and stocking data*. Remote Sensing of Environment, vol. 138, pages 232–244, 2013. (20)
- [Lillesand & Kiefer 2000] T.M. Lillesand et R.W. Kiefer. *Remote sensing and image interpretation*, New York, USA, 6th édition, 2000. (57)
- [Liu & Fieguth 2012] L. Liu et P. W. Fieguth. *Texture Classification from Random Features*. IEEE Transactions on Pattern Analysis and Machine Intelligence, vol. 34, no. 3, pages 574–586, 2012. (32)
- [Liu *et al.* 2013] C. Liu, J. Shang, P.W. Vachon et H. McNairn. *Multiyear Crop Monitoring Using Polarimetric RADARSAT-2 Data*. IEEE Transactions on Geoscience and Remote Sensing, vol. 51, no. 4, pages 2227–2240, 2013. (xiii, 51, 119)
- [Lobell & Field 2007] D. B. Lobell et C. B. Field. *Global scale climate–crop yield relationships and the impacts of recent warming*. Environmental Research Letters, vol. 2, no. 1, page 014002, 2007. (141)

- [Lu 2006] D. Lu. *The potential and challenge of remote sensing-based biomass estimation*. International Journal of Remote Sensing, vol. 27, no. 7, pages 1297–1328, 2006. (68, 71, 79)
- [Luckman 1998] A.J. Luckman. *The effects of topography on mechanisms of radar backscatter from coniferous forest and upland pasture*. IEEE Transactions on Geoscience and Remote Sensing, vol. 36, no. 5, pages 1830–1834, 1998. (27)
- [MacQueen 1967] J. B. MacQueen. *Some Methods for classification and Analysis of Multivariate Observations*. In Proceedings of 5-th Berkeley Symposium on Mathematical Statistics and Probability, Berkeley, University of California, vol. 6, pages 281–297, Press 1 :, 1967. (82)
- [Marechal et al. 2012] C. Marechal, E. Pottier, L. Hubert-Moy et S. Rapinel. *One year wetland survey investigations from quad-pol RADARSAT-2 time-series SAR images*. Canadian Journal of Remote Sensing, vol. 38, no. 03, pages 240–252, 2012. (27)
- [Marteau 2009] P.-F. Marteau. *Time Warp Edit Distance with Stiffness Adjustment for Time Series Matching*. IEEE Transactions on Pattern Analysis and Machine Intelligence, vol. 31, no. 2, pages 306–318, 2009. (33)
- [McNairn & Brisco 2004] H. McNairn et B. Brisco. *The application of C-band polarimetric SAR for agriculture : a review*. Canadian Journal of Remote Sensing, vol. 30, no. 3, pages 525–542, 2004. (xiii, 18, 25, 26, 27, 51, 99, 115, 119, 123, 126)
- [McNairn et al. 2000] H. McNairn, J.J. Van der Sanden, R.J. Brown et J. Ellis. *The potential of RADARSAT-2 for crop mapping and assessing crop condition*. In Proceedings of the 2nd International Conference on Geospatial Information in Agriculture and Forestry, vol. 2, pages 81–88, 2000. (27)
- [McNairn et al. 2002] H. McNairn, J. Ellis, J. J. Van Der Sanden, T. Hirose et R. J. Brown. *Providing crop information using RADARSAT-1 and satellite optical imagery*. International Journal of Remote Sensing, vol. 23, no. 5, pages 851–870, 2002. (26, 110)
- [McNairn et al. 2009] H. McNairn, J. Shang, X. Jiao et C. Champagne. *The Contribution of ALOS PALSAR Multipolarization and Polarimetric Data to Crop Classification*. IEEE Transactions on Geoscience and Remote Sensing, vol. 47, no. 12, pages 3981–3992, 2009. (27, 121, 126)
- [McRoberts & Tomppo 2007] R. E. McRoberts et E. O. Tomppo. *Remote sensing support for national forest inventories*. Remote Sensing of Environment, vol. 110, no. 4, pages 412–419, 2007. (53)
- [Mehner et al. 2004] H. Mehner, M. Cutler, D. Fairbairn et G. Thompson. *Remote sensing of upland vegetation : the potential of high spatial resolution satellite sensors*. Global Ecology and Biogeography, vol. 13, no. 4, pages 359–369, 2004. (xii)
- [Metera et al. 2010] E. Metera, T. Sakowski, K. Słoniewski et B. Romanowicz. *Grazing as a tool to maintain biodiversity of grassland - a review*. Animal Science Papers and Reports, vol. 28, no. 4, pages 315–334, 2010. (3)
- [Millward et al. 2006] A. A. Millward, J. M. Piwowar et P. J. Howarth. *Time-series analysis of medium-resolution, multisensor satellite data for identifying landscape change*. PE&RS, Photogrammetric Engineering & Remote Sensing, vol. 72, no. 6, pages 653–663, 2006. (32)
- [Montandon & Small 2008] L. M. Montandon et E. E. Small. *The impact of soil reflectance on the quantification of the green vegetation fraction from NDVI*. Remote Sensing of Environment, vol. 112, no. 4, pages 1835–1845, 2008. (21, 74)
- [Moreau & Le Toan 2003] S. Moreau et T. Le Toan. *Biomass quantification of Andean wetland forages using ERS satellite SAR data for optimizing livestock management*. Remote Sensing of Environment, vol. 84, no. 4, pages 477–492, 2003. (27)
- [Moreau et al. 2012] P. Moreau, L. Ruiz, F. Mabon, T. Raimbault, P. Durand, L. Delaby, S. Devienne et F. Vertès. *Reconciling technical, economic and environmental efficiency of farming systems*

- in vulnerable areas*. Agriculture, Ecosystems & Environment, vol. 147, pages 89–99, 2012. (67, 169)
- [Moreau *et al.* 2013] P. Moreau, L. Ruiz, F. Vertès, C. Baratte, L. Delaby, P. Faverdin, C. Gascuel-Oudou, B. Piquemal, E. Ramat, J. Salmon-Monviola et P. Durand. *CASIMOD’N : An agro-hydrological distributed model of catchment-scale nitrogen dynamics integrating farming system decisions*. Agricultural Systems, vol. 118, pages 41–51, 2013. (36)
- [Mountrakis *et al.* 2011] G. Mountrakis, J. Im et C. Ogole. *Support vector machines in remote sensing : A review*. ISPRS Journal of Photogrammetry and Remote Sensing, vol. 66, no. 3, pages 247–259, 2011. (53)
- [Muller 2002] S. Muller. *Appropriate agricultural management practices required to ensure conservation and biodiversity of environmentally sensitive grassland sites designated under Natura 2000*. Agriculture, Ecosystems & Environment, vol. 89, no. 3, pages 261–266, 2002. (3)
- [Nait Chabane & Belhadj-Aissa 2009] A. Nait Chabane et A. Belhadj-Aissa. *Classification des images radar polarimétrique selon les mécanismes de rétrodiffusion par les supports à vaste marge*. In Troisième Journées d’Animation Scientifique du réseau de Télédétection de l’AUF, Alger, 2009. (53)
- [Neigh *et al.* 2008] C. S.R. Neigh, C. J. Tucker et J. R.G. Townshend. *North American vegetation dynamics observed with multi-resolution satellite data*. Remote Sensing of Environment, vol. 112, no. 4, pages 1749–1772, 2008. (21)
- [Nilson 1971] T. Nilson. *A theoretical analysis of the frequency of gaps in plant stands*. Agricultural and Forest Meteorology, no. 8, pages 25–28, 1971. (60)
- [Ojala *et al.* 2002] T. Ojala, M. Pietikainen et T. Maenpaa. *Multiresolution gray-scale and rotation invariant texture classification with local binary patterns*. IEEE Transactions on Pattern Analysis and Machine Intelligence, vol. 24, no. 7, pages 971–987, 2002. (32)
- [Park & Moon 2007] S.-E. Park et W.M. Moon. *Unsupervised Classification of Scattering Mechanisms in Polarimetric SAR Data Using Fuzzy Logic in Entropy and Alpha Plane*. IEEE Transactions on Geoscience and Remote Sensing, vol. 45, no. 8, pages 2652–2664, 2007. (121)
- [Peeters 2009] A. Peeters. *Importance, evolution, environmental impact and future challenges of grasslands and grassland-based systems in Europe*. Grassland Science, vol. 55, no. 3, pages 113–125, 2009. (99)
- [Peregon & Yamagata 2013] A. Peregon et Y. Yamagata. *The use of ALOS/PALSAR backscatter to estimate above-ground forest biomass : A case study in Western Siberia*. Remote Sensing of Environment, vol. 137, pages 139–146, 2013. (18)
- [Petitjean *et al.* 2010] F. Petitjean, P. Gançarski, F. Maseglia et G. Forestier. *Analysing Satellite Image Time Series by Means of Pattern Mining*. In Intelligent Data Engineering and Automated Learning – IDEAL’10, numéro 6283 de Lecture Notes in Computer Science, Springer Berlin Heidelberg, pages 45–52, 2010. (33)
- [Petitjean *et al.* 2011] F. Petitjean, J. Inglada et P. Gançarski. *Clustering of satellite image time series under Time Warping*. In 6th International Workshop on the Analysis of Multi-temporal Remote Sensing Images, (Multi-Temp)’11 , pages 69–72, 2011. (33)
- [Petitjean *et al.* 2012] F. Petitjean, J. Inglada et P. Gançarski. *Satellite Image Time Series Analysis Under Time Warping*. IEEE Transactions on Geoscience and Remote Sensing, vol. 50, no. 8, pages 3081–3095, 2012. (33)
- [Plantureux *et al.* 2012] S. Plantureux, E. Pottier et P. Carrère. *La prairie permanente : nouveaux enjeux, nouvelles définitions ?* Fourrages, vol. 211, pages 181–193, 2012. (4)

- [Potithec *et al.* 2013] S. Potithec, S. Nagai, K. N. Nasahara, H. Muraoka et R. Suzuki. *Two separate periods of the LAI–VIs relationships using in situ measurements in a deciduous broadleaf forest*. *Agricultural and Forest Meteorology*, vol. 169, pages 148–155, 2013. (23)
- [Poudevigne & Alard 1997] I. Poudevigne et D. Alard. *Landscape and Agricultural Patterns in Rural Areas : a Case Study in the Brionne Basin, Normandy, France*. *Journal of Environmental Management*, vol. 50, no. 4, 1997. (99)
- [Pousset 2002] J. Pousset. *Prairies temporaires : Les installer dans de bonnes conditions*. *Bulletin du Pôle Scientifique Bio Normandie*, pages 13–14, 2002. (10)
- [Price *et al.* 2002] K. P. Price, X. Guo et J. M. Stiles. *Optimal Landsat TM band combinations and vegetation indices for discrimination of six grassland types in eastern Kansas*. *International Journal of Remote Sensing*, vol. 23, no. 23, pages 5031–5042, 2002. (xiii, 47, 67)
- [Price 1994] J.C. Price. *How unique are spectral signatures ?* *Remote Sensing of Environment*, vol. 49, no. 3, pages 181–186, 1994. (82)
- [Rapinel *et al.* 2014] S. Rapinel, B. Clément, S. Magnanon, V. Sellin et L. Hubert-Moy. *Identification and mapping of natural vegetation on a coastal site using a Worldview-2 satellite image*. *Journal of Environmental Management*, vol. 144, pages 236–246, 2014. (21)
- [Rapinel 2012] S. Rapinel. *Contribution de la télédétection à l'évaluation des fonctions des zones humides : De l'observation à la modélisation prospective*. Thèse de géographie, Université Rennes 2, 384p., 2012. (21)
- [Ribbes 1999] F. Ribbes. *Rice field mapping and monitoring with RADARSAT data*. *International Journal of Remote Sensing*, vol. 20, no. 4, pages 745–765, 1999. (119)
- [Richards 2012] J. A. Richards. *Remote sensing digital image analysis : An introduction*. Springer, 5th édition, 2012. (31, 116)
- [Richardson *et al.* 1982] A.J. Richardson, C.L. Wiegand, G.F. Arkin, P.R. Nixon et A.H. Gerbermann. *Remotely-sensed spectral indicators of sorghum development and their use in growth modeling*. *Agricultural Meteorology*, vol. 26, no. 1, pages 11–23, 1982. (23)
- [Richter & Atzberger 2012] K. Richter et C. Atzberger. *Spatially constrained inversion of radiative transfer models for improved LAI mapping from future Sentinel-2 imagery*. *Remote Sensing of Environment*, vol. 120, page 208–218, 2012. (170)
- [Richter *et al.* 2011] K. Richter, C. Atzberger, F. Vuolo et G. D'Urso. *Evaluation of Sentinel-2 Spectral Sampling for Radiative Transfer Model Based LAI Estimation of Wheat, Sugar Beet, and Maize*. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, vol. 4, no. 2, pages 458–464, 2011. (170)
- [Richter *et al.* 2012] K. Richter, T. B. Hank, F. Vuolo, W. Mauser et G. D'Urso. *Optimal Exploitation of the Sentinel-2 Spectral Capabilities for Crop Leaf Area Index Mapping*. *Remote Sensing*, vol. 4, no. 3, pages 561–582, 2012. (xii, 170)
- [Rondeaux *et al.* 1996] G. Rondeaux, M. Steven et F. Baret. *Optimization of soil-adjusted vegetation indices*. *Remote Sensing of Environment*, vol. 55, no. 2, pages 95–107, 1996. (99)
- [Rouse *et al.* 1974] J. Rouse, R. Haas, J. Schell, D. Deering et J. Harlan. *Monitoring the vernal advancement of retrogradation of natural vegetation*. NASA/GSFC, Type III, Final report. Greenbelt, MD, Etats-Unis, 371 p., 1974. (21, 49, 58)
- [Ruget 2013] F. Ruget. *Impacts des changements climatiques sur les productions de fourrages (prairies, luzerne, maïs) : variabilité selon les régions et les saisons*, *Fourrages*, vol. 214, 2013. (67)
- [Sahbi *et al.* 2011] H. Sahbi, J.-Y. Audibert et R. Keriven. *Context-Dependent Kernels for Object Classification*. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, vol. 33, no. 4, pages 699–708, 2011. (32)

- [Scholkopf & Smola 2001] B. Scholkopf et A. J. Smola. *Learning with kernels : Support vector machines, regularization, optimization, and beyond*. MIT Press, Cambridge, MA, USA, 2001. (32)
- [Schuster *et al.* 2011] C. Schuster, I. Ali, P. Lohmann, A. Frick, M. Förster et B. Kleinschmit. *Towards Detecting Swath Events in TerraSAR-X Time Series to Establish NATURA 2000 Grassland Habitat Swath Management as Monitoring Parameter*. *Remote Sensing*, vol. 3, no. 12, pages 1308–1322, 2011. (xii, 163)
- [Schuster *et al.* 2015] C. Schuster, T. Schmidt, C. Conrad, B. Kleinschmit et M. Förster. *Grassland habitat mapping by intra-annual time series analysis – Comparison of RapidEye and TerraSAR-X satellite data*. *International Journal of Applied Earth Observation and Geoinformation*, vol. 34, pages 25–34, 2015. (32, 53)
- [Shimodaira *et al.* 2001] H. Shimodaira, K.-I. Noma, M. Nakai et S. Sagayama. *Dynamic Time-Alignment Kernel in Support Vector Machine*. *Neural Information Processing Systems*, pages 921–928, 2001. (148)
- [Singh 1984] A. Singh. *Some clarifications about the pairwise divergence measure in remote sensing*. *International Journal of Remote Sensing*, vol. 5, no. 3, pages 623–627, 1984. (116)
- [Smith & Buckley 2011] A. M. Smith et J. R. Buckley. *Investigating RADARSAT-2 as a tool for monitoring grassland in western Canada*. *Canadian Journal of Remote Sensing*, vol. 37, no. 1, pages 93–102, 2011. (xiii, 26, 27, 51, 110, 123)
- [Smith *et al.* 2006] A. M. Smith, D. J. Major, M. J. Hill, W. D. Willms, B. Brisco, C. W. Lindwall et R. J. Brown. *Airborne synthetic aperture radar analysis of rangeland revegetation of a mixed prairie*. *Journal of Range Management Archives*, vol. 47, no. 5, pages 385–391, 2006. (26)
- [Soudani *et al.* 2006] K. Soudani, C. François, G. le Maire, V. Le Dantec et E. Dufrêne. *Comparative analysis of IKONOS, SPOT, and ETM+ data for leaf area index estimation in temperate coniferous and deciduous forest stands*. *Remote Sensing of Environment*, vol. 102, no. 1–2, pages 161–175, 2006. (50)
- [Soussana & Lüscher 2007] J-F. Soussana et A. Lüscher. *Temperate grasslands and global atmospheric change : a review*. *Grass and Forage Science*, vol. 62, no. 2, page 127–134, 2007. (3, 4, 67)
- [Soussana 2013] J.-F. Soussana. *S'adapter au changement climatique : Agriculture, écosystèmes et territoires*. Editions Quae, 2013. (67)
- [Stigler 2008] S. M. Stigler. *Karl Pearson's Theoretical Errors and the Advances They Inspired*. *Statistical Science*, vol. 23, no. 2, pages 261–271, 2008. (82)
- [Sullivan *et al.* 2010] C. A. Sullivan, M. S. Skeffington, M. J. Gormally et J. A. Finn. *The ecological status of grasslands on lowland farmlands in western Ireland and implications for grassland classification and nature value assessment*. *Biological Conservation*, vol. 143, no. 6, pages 1529–1539, 2010. (xi)
- [Swain & King 1973] P. H. Swain et R. C. King. *Two effective feature selection criteria for multispectral remote sensing*. In *Proceedings of the First International Joint Conference on Pattern Recognition*, pages 536–540, 1973. (31, 116)
- [Tanré *et al.* 1990] D. Tanré, C. Deroo, P. Duhaut, M. Herman, J. J. Morcette, J. Perbos et P. Y. Deschamps. *Technical note Description of a computer code to simulate the satellite signal in the solar spectrum : the 5S code*. *International Journal of Remote Sensing*, vol. 11, no. 4, pages 659–668, 1990. (47)
- [Theau & Zerourou 2008] J.P. Theau et A. Zerourou. *Herb'âge, une méthode de calcul des sommes de températures pour la gestion des prairies*. *Les Cahiers d'Orphée*, pages 93–102, 2008. (6)

- [Thomas *et al.* 1987] I. L. Thomas, N. P. Ching, V. M. Benning et J. A. D’Aguanno. *A review of multi-channel indices of class separability*. International Journal of Remote Sensing, vol. 8, no. 3, pages 331–350, 1987. (31, 32, 158)
- [Toby & Ripley 1997] N.C. Toby et D.A. Ripley. *On the relation between NDVI, fractional vegetation cover, and leaf area index*. Remote Sensing of Environment, vol. 62, no. 3, pages 241–252, 1997. (23)
- [Tomasi *et al.* 2004] G. Tomasi, F. Van den Berg et C. Andersson. *Correlation optimized warping and dynamic time warping as preprocessing methods for chromatographic data*. Journal of Chemometrics, vol. 18, no. 5, pages 231–241, 2004. (33)
- [Touzi *et al.* 2007] R. Touzi, A. Deschamps et G. Rother. *Wetland characterization using polarimetric RADARSAT-2 capability*. Canadian Journal of Remote Sensing, vol. 33, no. S1, pages S56–S67, 2007. (27)
- [Touzi 2007] R. Touzi. *Target Scattering Decomposition in Terms of Roll-Invariant Target Parameters*. IEEE Transactions on Geoscience and Remote Sensing, vol. 45, no. 1, pages 73–84, 2007. (27)
- [Tucker *et al.* 1985] C.J. Tucker, C.L. Vanpraet, M.J. Sharman et G. Van Ittersum. *Satellite remote sensing of total herbaceous biomass production in the senegalese sahel : 1980–1984*. Remote Sensing of Environment, vol. 17, no. 3, pages 233–249, 1985. (20)
- [Tucker 1979] C.J. Tucker. *Red and Photographic Infrared Linear Combinations for Monitoring Vegetation*. Remote Sensing of Environment, vol. 8, no. 2, pages 127–150, 1979. (21, 49)
- [Ulaby & Dobson 1989] F.T. Ulaby et M.C. Dobson. *Handbook of radar scattering statistics for terrain*. Artech House, Inc., Dedham, 1989. (27)
- [Ulaby & Elachi 1990] F.T. Ulaby et C. Elachi. *Radar polarimetry for geoscience applications*. Artech House, Inc., Dedham, 1990. (25)
- [Ulaby *et al.* 1982] F. T. Ulaby, R. K. Moore et A. K. Fung. *Microwave remote sensing : Active and passive*, vol. ii – radar remote sensing and surface scattering and emission theory. Addison-Wesley Publishing Company, Advanced Book Program/World Science Division, 1982. (17)
- [Van Niel *et al.* 2005] T. G. Van Niel, T. R. McVicar et B. Datt. *On the relationship between training sample size and data dimensionality : Monte Carlo analysis of broadband multi-temporal classification*. Remote Sensing of Environment, vol. 98, no. 4, pages 468–480, 2005. (31)
- [Vanden Borre *et al.* 2011] J. Vanden Borre, D. Paelinckx, C. A. Mùcher, L. Kooistra, B. Haest, G. De Blust et A. M. Schmidt. *Integrating remote sensing in Natura 2000 habitat monitoring : Prospects on the way forward*. Journal for Nature Conservation, vol. 19, no. 2, pages 116–125, 2011. (xii)
- [Vannier 2012] C. Vannier. *Analyse spatiale de structures paysagères en contexte agricole bocager*. Cybergeog : European Journal of Geography, 2012. (20)
- [Vapnik 1995] V. N. Vapnik. *The nature of statistical learning theory*. Springer-Verlag New York, Inc., New York, NY, USA, 1995. (54)
- [Verhoef 1984] W. Verhoef. *Light scattering by leaf layers with application to canopy reflectance modeling : The SAIL model*. Remote Sensing of Environment, vol. 16, no. 2, pages 125–141, 1984. (24)
- [Vermote *et al.* 1997] E.F. Vermote, D. Tanre, J.L. Deuze, M. Herman et J.-J. Morcette. *Second Simulation of the Satellite Signal in the Solar Spectrum, 6S : an overview*. IEEE Transactions on Geoscience and Remote Sensing, vol. 35, no. 3, pages 675–686, 1997. (47)

- [Vertès *et al.* 2007] F. Vertès, D.J. Hatch, G.L. Velthof, F. Taube, F. Laurent, P. Loiseau et S. Recous. *Short-term and cumulative effects of grassland cultivation on nitrogen and carbon cycling in ley-arable rotations*. In *Grassland Science in Europe*, pages 227–246, 2007. (3, 10, 67, 99, 141)
- [Vertès *et al.* 2007] F. Vertès, J.C. Simon, F. Laurent et A. Besnard. *Prairies et qualité de l'eau. Evaluation des risques de lixiviation d'azote et optimisation des pratiques*. Fourrages, pages 423–440, 2007. (xi, 4, 10)
- [Vertès *et al.* 2010] F. Vertès, M. Benoit et J.M. Dorioz. *Couvertures herbacées pérennes et enjeux environnementaux (en particulier eutrophisation) : atouts et limites*. Fourrages, vol. 202, pages 83–94, 2010. (3, 10)
- [Viña *et al.* 2011] A. Viña, A. A. Gitelson, A. L. Nguy-Robertson et Y. Peng. *Comparison of different vegetation indices for the remote assessment of green leaf area index of crops*. *Remote Sensing of Environment*, vol. 115, no. 12, pages 3468–3478, 2011. (21, 23, 73, 83, 89)
- [Vigneau-Loustau & Huyghe 2008] L. Vigneau-Loustau et C. Huyghe. *Stratégie fourragères*. 2008. (3, 9)
- [Voormansik *et al.* 2013] K. Voormansik, T. Jagdhuber, A. Olesk, I. Hajnsek et K. P. Papathanassiou. *Towards a detection of grassland cutting practices with dual polarimetric TerraSAR-X data*. *International Journal of Remote Sensing*, vol. 34, no. 22, pages 8081–8103, 2013. (26, 163)
- [Wang *et al.* 2005] J. Wang, P. M. Rich, K. P. Price et W. Dean Kettle. *Relations between NDVI, Grassland Production, and Crop Yield in the Central Great Plains*. *Geocarto International*, vol. 20, no. 3, pages 5–11, 2005. (23, 58, 68)
- [Wang *et al.* 2013] X. Wang, L. Ge et X. Li. *Pasture Monitoring Using SAR with COSMO-SkyMed, ENVISAT ASAR, and ALOS PALSAR in Otway, Australia*. *Remote Sensing*, vol. 5, no. 7, pages 3611–3636, 2013. (18)
- [Wardlow & Egbert 2008] B. D. Wardlow et S. L. Egbert. *Large-area crop mapping using time-series MODIS 250 m NDVI data : An assessment for the U.S. Central Great Plains*. *Remote Sensing of Environment*, vol. 112, no. 3, pages 1096–1116, 2008. (32)
- [Wei 2010] X. Wei. *Biomass Estimation : A Remote Sensing Approach*. *Geography Compass*, vol. 4, no. 11, page 1635–1647, 2010. (68, 99)
- [Weiss & Baret 2010] M. Weiss et F. Baret. *CAN-EYE V6.1 User Manual*. EMMAH, INRA, 2010. (60)
- [Weiss *et al.* 2000] M. Weiss, F. Baret, R. B. Myneni, A. Pragnère et Y. Knyazikhin. *Investigation of a model inversion technique to estimate canopy biophysical variables from spectral and directional reflectance data*. *Agronomie*, vol. 20, no. 1, pages 3–22, 2000. (50)
- [Weiss *et al.* 2004] M. Weiss, F. Baret, G. J. Smith, I. Jonckheere et P. Coppin. *Review of methods for in situ leaf area index (LAI) determination : Part II. Estimation of LAI, errors and sampling*. *Agricultural and Forest Meteorology*, vol. 121, no. 1-2, pages 37–53, 2004. (60)
- [Weiss *et al.* 2007] M. Weiss, F. Baret, S. Garrigues et R. Lacaze. *LAI and fAPAR CYCLOPES global products derived from VEGETATION. Part 2 : validation and comparison with MODIS collection 4 products*. *Remote Sensing of Environment*, vol. 110, no. 3, pages 317–331, 2007. (50)
- [Wessels *et al.* 2004] K. J. Wessels, R. S. De Fries, J. Dempewolf, L. O. Anderson, A. J. Hansen, S. L. Powell et E. F. Moran. *Mapping regional land cover with MODIS data for biological conservation : Examples from the Greater Yellowstone Ecosystem, USA and Pará State, Brazil*. *Remote Sensing of Environment*, vol. 92, no. 1, pages 67–83, 2004. (21)
- [White *et al.* 2000] R. White, S. Murray et Rohweder M. *Pilote Analysis of Global Ecosystems : Grassland ecosystems*. World Resources Institute, 2000. (67)

- [Wright & Wimberly 2013] C. K. Wright et M. C. Wimberly. *Recent land use change in the Western Corn Belt threatens grasslands and wetlands*. Proceedings of the National Academy of Sciences, vol. 110, no. 10, pages 4134–4139, 2013. (xi)
- [Wu et al. 2007] J. Wu, D. Wang et M. E. Bauer. *Assessing broadband vegetation indices and Quick-Bird data in estimating leaf area index of corn and potato canopies*. Field Crops Research, vol. 102, no. 1, pages 33–42, 2007. (23, 74, 83, 89)
- [Wu et al. 2010] C. Wu, X. Han, Z. Niu et J. Dong. *An evaluation of EO-1 hyperspectral Hyperion data for chlorophyll content and leaf area index estimation*. International Journal of Remote Sensing, vol. 31, no. 4, page 1079, 2010. (23)
- [Wylie et al. 2002] B.K Wylie, D.J Meyer, L.L Tieszen et S Mannel. *Satellite mapping of surface biophysical parameters at the biome scale over the North American grasslands : A case study*. Remote Sensing of Environment, vol. 79, no. 2–3, pages 266–278, 2002. (23)
- [Xie et al. 2008] Y. Xie, Z. Sha et M. Yu. *Remote sensing imagery in vegetation mapping : a review*. Journal of Plant Ecology, vol. 1, no. 1, pages 9–23, 2008. (11, 18, 47, 99)
- [Yang et al. 2011] C. Yang, J. H. Everitt et D. Murden. *Evaluating high resolution SPOT 5 satellite imagery for crop identification*. Computers and Electronics in Agriculture, vol. 75, no. 2, pages 347–354, 2011. (xiii, 47)
- [Zhang & Guo 2008] C. Zhang et X. Guo. *Monitoring northern mixed prairie health using broadband satellite imagery*. International Journal of Remote Sensing, vol. 29, no. 8, pages 2257–2271, 2008. (20, 50, 68)
- [Zhang et al. 2003] X. Zhang, M.A. Friedl, C.B. Schaaf, A.H. Strahler, J.C.F. Hodges, F. Gao, B.C. Reed et A. Huete. *Monitoring vegetation phenology using MODIS*. Remote Sensing of Environment, vol. 84, no. 3, pages 471–475, 2003. (20)
- [Zhang et al. 2007] J. Zhang, M. Marszałek, S. Lazebnik et C. Schmid. *Local Features and Kernels for Classification of Texture and Object Categories : A Comprehensive Study*. International Journal of Computer Vision, vol. 73, no. 2, pages 213–238, 2007. (32)
- [Zhang et al. 2010] D. Zhang, W. Zuo, D. Zhang et H. Zhang. *Time Series Classification Using Support Vector Machine with Gaussian Elastic Metric Kernel*. In 20th International Conference on Pattern Recognition (ICPR'10), pages 29–32, 2010. (33, 148)
- [Zhang 2001] T. Zhang. *An Introduction to Support Vector Machines and Other Kernel-Based Learning Methods*. AI Magazine, vol. 22, no. 2, page 103, 2001. (54)
- [Zhao 2014] Y. Zhao. *Modélisation qualitative des agro-écosystèmes et aide à leur gestion par utilisation d'outils de model-checking*. PhD thesis, Université Rennes 1, 146p., 2014. (146)
- [Zheng & Moskal 2009] G. Zheng et L. M. Moskal. *Retrieving Leaf Area Index (LAI) Using Remote Sensing : Theories, Methods and Sensors*. Sensors, vol. 9, no. 4, pages 2719–2745, 2009. (23)





# Annexe 1

# Agricultural practices in grasslands detected by spatial remote sensing

Pauline Dusseux · Françoise Vertès ·  
Thomas Corpetti · Samuel Corgne ·  
Laurence Hubert-Moy

Received: 18 December 2013 / Accepted: 12 August 2014  
© Springer International Publishing Switzerland 2014

**Abstract** The major decrease in grassland surfaces associated with changes in their management that has been observed in many regions of the earth during the last half century has major impacts on environmental and socio-economic systems. This study focuses on the identification of grassland management practices in an intensive agricultural watershed located in Brittany, France, by analyzing the intra-annual dynamics of the surface condition of vegetation using remotely sensed and field data. We studied the relationship between one vegetation index (NDVI) and two biophysical variables (LAI and fCOVER) derived from a series of three SPOT images on one hand and measurements collected during field campaigns achieved on 120 grasslands on the other. The results show that the LAI appears as the best predictor for monitoring grassland mowing and grazing. Indeed, because of its ability to characterize vegetation status, LAI estimated from remote sensing data is a relevant variable to identify these practices. LAI values derived from the SPOT images were then classified based on the K-Nearest Neighbor (KNN) supervised algorithm. The results point out that the distribution of grassland management practices such as grazing and mowing can be mapped very

accurately (Kappa index=0.82) at a field scale over large agricultural areas using a series of satellite images.

**Keywords** Grasslands · Mowing · Pasture · Spectrometry · Visible-infrared remote sensing · Leaf Area Index

## Introduction

A major decrease in grassland surfaces associated with changes in their management has been observed in many regions of the earth during the last half century (Huyghe et al. 2014; Wright and Wimberly 2013; Peeters 2009; Poudevigne and Alard 1997). These land cover and land use changes that are often associated with agriculture intensification may have major impacts on environmental systems by increasing water and air pollution, soil degradation or biodiversity loss (Lobell and Field 2007), and on socio-economic systems for stock and winter fodder (Huyghe et al. 2014; Batáry et al. 2007). Moreover, the functional role of grasslands changes with intensive agricultural practices like the increase in fertilization inputs or the annual number of mowing or grazing events. For example, the protective role of grassland against nitrate leaching as well as the carbon storage in soils decreases with the conversion of grass into cropland or with overgrazing (Vertès et al. 2007; Arrouays et al. 2001). Moreover, in the context of the increase of agricultural fertilizer and changes in agricultural practices, eutrophication phenomenon and green algae tides on coastal area can result from the soil

---

P. Dusseux (✉) · T. Corpetti · S. Corgne · L. Hubert-Moy  
Laboratoire LETG Rennes COSTEL, UMR CNRS 6554,  
Université Rennes 2, Place du Recteur Henri Le Moal,  
35043 Rennes Cedex, France  
e-mail: pauline.dusseux@gmail.com

F. Vertès  
UMR INRA-Agrocampus 1069 SAS, 4 rue Stang Vihan,  
29000, Quimper, France

Published online: 03 September 2014

 Springer

degradation and water pollution. Therefore, the evaluation of grassland status and the characterization of crop successions, including the share, duration, and management of grasslands in key arable rotations are key issues for sustainable agriculture. Such knowledge might be obtained by combining farm survey questionnaires, but previous studies demonstrated huge difficulties in achieving such a task in a large field network.

Vegetation density and other parameters related to vegetation cover like crop height and biomass can be estimated from remote sensing data, either by using empirical or semi-empirical methods based on the use of vegetation indices or by applying radiative transfer models to estimate parameters related to vegetation (Darvishzadeh et al. 2011; Gamon et al. 1995; Gao et al. 2012; Jacquemoud et al. 2009). Vegetation indices and biophysical variables estimated from satellite images are relatively well correlated to vegetation growth, fractional vegetation cover, crop height, and green biomass (Asam et al. 2013; Viña et al. 2011; Wei 2010; Zhang and Guo 2008; Guo et al. 2000; Rondeaux et al. 1996; Friedl et al. 1994; Chen and Black 1991).

High spatial and temporal resolution remote sensing images are required to precisely identify grassland management on agricultural areas covering more than a few hectares (Dusseux et al. 2011). Until now, grassland monitoring by remote sensing has indeed been greatly limited both by the low revisit frequency of high spatial resolution sensors and the low spatial resolution of high revisit frequency sensors (Lecerf et al. 2005). Upcoming new high spatial and temporal resolution sensors such as Sentinel-2 and *VenµS* offer new prospects for studying grassland management at the field scale.

In the context of the future exploitation of these new time series of remotely sensed data, this study focuses on the monitoring of grassland management practices by analyzing the intra-annual dynamics of the surface condition of vegetation through vegetation indices and biophysical variables derived from a series of satellite images, yet it is still necessary to explore how accurately satellite images can describe the surface vegetation condition compared to field data and how accurately they can identify practices applied on grasslands over large agricultural areas.

Thus, the objectives of the study are to (1) study the relationship between vegetation indices and biophysical variables derived from a series of high spatial resolution remote sensing images and measurements collected in the field in order to identify practices applied to

grasslands and (2) determine which index or variable is the best predictor to monitor these practices.

Three grassland management practices were studied for this work: grazing, mowing, and mixed management combining grazing and mowing during the vegetation season. While surface conditions of vegetation vary with land management, agricultural practices can be identified based on the analysis of biomass indices, crop height, or fractional vegetation cover. Grazing results in a decrease in biomass and crop height; soil being visible not only on human scale at ground level but also on high spatial resolution remote sensing images in the case of overgrazing. Mowing results in a strong and fast decrease in biomass and crop height with visible soil. Information on vegetation cover derived from remote sensing data through the calculation of vegetation indices like the Normalized Difference Vegetation Index (NDVI) or through biophysical variables like the Leaf Area Index (LAI) or the fraction of Vegetation Cover (fCOVER) can thus be used to monitor vegetation growth, estimate biomass, and assess management practices (Wei 2010; Friedl et al. 1994). Indeed, an increase in these indices and variables provide information on vegetation growth status, whereas a decrease of crop height and biomass revealed by a decrease in the NDVI, the LAI, and the fCOVER gives information about management practices.

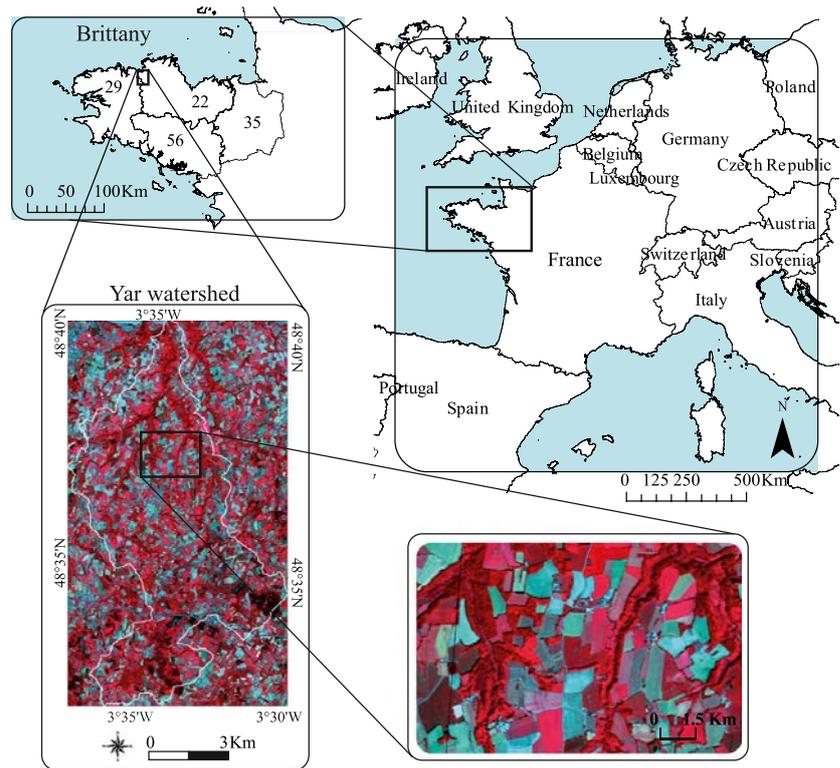
Therefore, we assessed the relationship between remotely sensed images and field data through the one vegetation index, the NDVI, and the LAI and fCOVER biophysical variables.

## Materials and methods

### Study site

The study site is a watershed, namely the Yar, an area of 61.5 km<sup>2</sup> located on the northern coast of Brittany in western France (Fig. 1). This area that is characterized by agricultural dominance and intensive farming is mainly geared towards dairy cattle production and is subjected to pollution due to agriculture activities. Though the nitrate concentration in surface water is far below the European drinking water standard (about 35 vs 50 mg nitrate per liter), the sensitivity of the site to eutrophication is very high, and the beaches have been affected by green algae tides for the past 40 years. To understand the role of farming systems and agricultural

**Fig. 1** Location of the study site and extract of a SPOT 5 image, June 26 2010, false color (RGB: NIR, R, G)



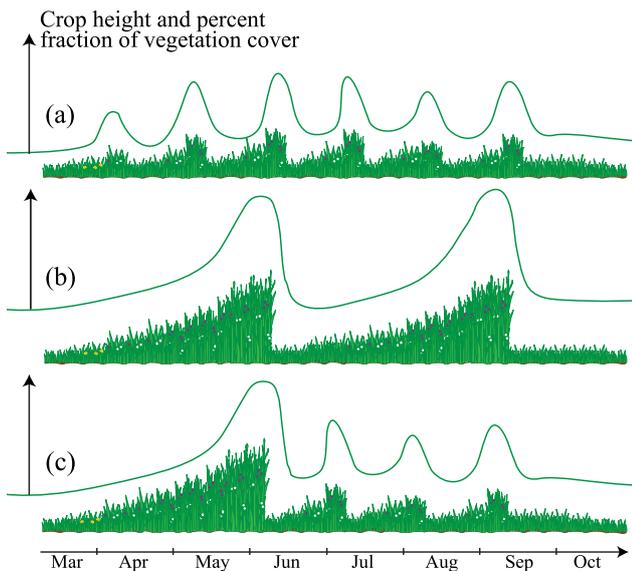
practices in nutrient losses, this area has been intensively monitored since the 1990s, and many studies have been realized to observe and understand the watershed functioning (Corgne et al. 2002). High nitrogen rates in rivers were largely due to conversion of grasslands first from perennial to annual cover and then to croplands and pastures and excessive fertilization, which have been observed for several years on this site, as described by Moreau et al. (2012). The consequences on environmental and economic activities have led the authorities to make decisions to restore water quality and reduce green algae development. The agricultural area (AA) covers 2/3 of the total area in the Yar watershed and includes a large proportion of grasslands (60 % of AA) located for a small part in wetlands and implementing various dairy and beef production systems (organic, conventional, etc.). Grassland field size is on average less than 1 ha, which is relatively small. Three main types of grassland management practices can be observed on this study site, namely grazing, mowing, and mixed management (grazing and mowing). Around 55 % of the grasslands are used mainly for grazing, 5 % for mowing, and 40 % by mixed management. Grazing describes a type of feeding in which herbivores directly feed on grasses. Mowing refers to the cutting of grass with a mechanical device for hay or silage,

whereas mixed management is the combined use of grazing and mowing in the same field, depending on the farmer's needs. They are representative of the variety of practices associated with grasslands in western France.

#### Data acquisition

##### *Field data collection*

Field campaigns were conducted on a monthly basis on grasslands during the growing season of 2010 from March to November. Information on vegetation (biomass) and agricultural practices (grazing, mowing, or mixed management) was collected for 120 fields within the study site. For 20 of these fields, additional information was collected: vegetation cover (percent fraction), crop height, spectral measurements using a spectroradiometer, and LAI measurements from hemispherical photographs. All this information can be related to variables or indices estimated from remote sensing data—NDVI, LAI, and fCOVER—are directly correlated to crop height and fractional vegetation cover. Thus, intra-annual temporal vegetation dynamics provided information on agricultural practices (Fig. 2). Each



**Fig. 2** Simulation of intra-annual temporal profiles for grazing (a), mowing (b), and mixed grassland management (c)

decrease in parameters, the intensity and the intra-annual dynamics provide information on a grassland practice.

Spectroradiometer and LAI measurements were carried out on several grassland types according to the surface condition depending on agricultural management, phenological development stages, and fractional vegetation cover.

The Analytical Spectral Devices (ASD) FieldSpec3 spectrometer was used to measure the in situ reflectance. This spectrometer has a high resolution with a 350–2,500 nm spectral range and 1 nm spectral resolution with a 25° field of view (ASD 2000). The sampling was done while walking along a transect running the length of every grassland field. This ensured that the spectral measurements covered the range of the reflectance variance within each field. Ten spectrometer measurements per field were taken about 1.5 m above the vegetation the middle of the day (around 10:30 UTC). Each of these spectrometer values is an average of 50 spectrometer measurements. A white reference Spectralon calibration panel was used between each measurement to account for the changing atmospheric conditions and irradiance of the sun, removing the effects of solar illumination (Lillesand and Kiefer 2000). The fields were visited monthly during the growing season from March to October 2010.

Hemispherical photographs were acquired using a Nikon D300S camera mounted with a Nikon 10.5 mm f/2.8G ED AF DX Fisheye Nikkor Lens that allows an

effective field of view of 180°. The resulting image size is 4,288 by 2,848 pixels. Images were acquired using a downward looking (looking at the soil) configuration at about 1 m above the top of the canopy. A minimum of 12 pictures were taken for every visited field. Each set of hemispherical photographs (by visited field) is supposed to represent the canopy's variability (Weiss et al. 2004) and will produce a single LAI value.

Field measurements were performed on grasslands mainly composed of ryegrass and clover. Vegetation species were quite similar from one field to another. Moreover, the aim being to compare field data collection with remote sensing data, according to the satellite images' spatial resolution, species cannot be discriminated. Thus, the number of samples varies according to the month and the vegetation state, with the surface condition depending on agricultural management, phenological stages, and climate condition.

In addition to these measurements, surveys were conducted on four farms representative of grassland management in the study site area to precisely determine some key dates for agricultural practices: the beginning and ending of grazing, number of grazing periods during the year, number of mowing events during the season, etc.

#### Remote sensing data

Three cloud-free remotely sensed images derived from optical sensors with high spatial resolution acquired in 2010 during the vegetation period were used to identify grassland management practices on the study site (Table 1). The spatial resolution of the satellite images (5 and 10 m) is too coarse for the size of grassland fields (1 ha on average) in the study area to appreciate intra-field pattern heterogeneity (Lefebvre et al. 2011). Consequently, only spectral information (spectral range ( $\mu\text{m}$ ) G, 0.5–0.59; R, 0.61–0.68; and NIR, 0.78–0.89)

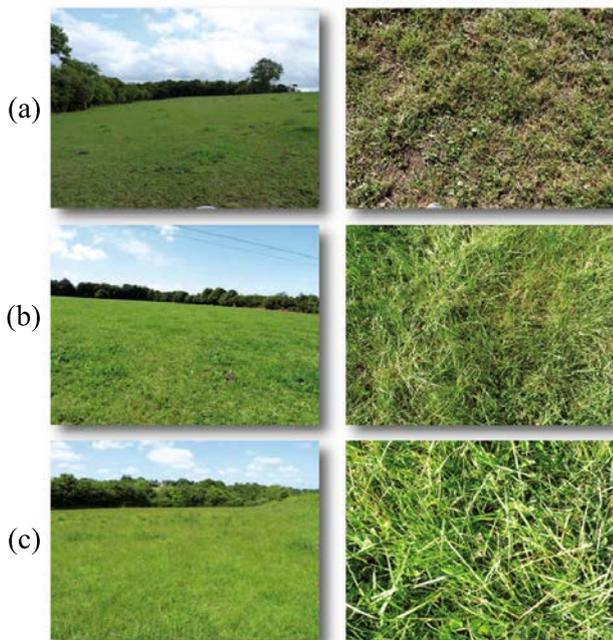
**Table 1** Characteristics of satellite images

Date (DOY)	Sensor	Spatial resolution (m)	Sun elevation (°)	View zenith angle
19 April 2010 (109)	SPOT 5	5×5	51.5	20.9
21 May 2010 (141)	SPOT 5	10×10	59.8	0.43
26 June 2010 (177)	SPOT 5	5×5	63.1	10.8

was used to classify grassland practices at the field scale. These images were chosen because the acquisition dates were close to field campaigns dates.

Data processing

The spectrometer measurements, the hemispherical photographs, and the samples extracted from satellite images were sorted by field, by month of acquisition, and by surface condition (depending on agricultural management, crop height, phenological development stages, and fractional vegetation cover) to study their temporal dynamics during the growing season and, thus, the agricultural practices. According to surface conditions which depend on agricultural management, crop height, phenological development stages, and fractional vegetation cover, spectral measurements were classified according to three vegetation statuses: status 1 (S1) corresponding to a crop height of less than 10 cm with soil visible (coverage rate <70 %), status 2 (S2) to a crop height of between 10 and 20 cm (coverage rate >90 %), and status 3 (S3) to a crop height greater than 20 cm (coverage rate=100 %) (Fig. 3).

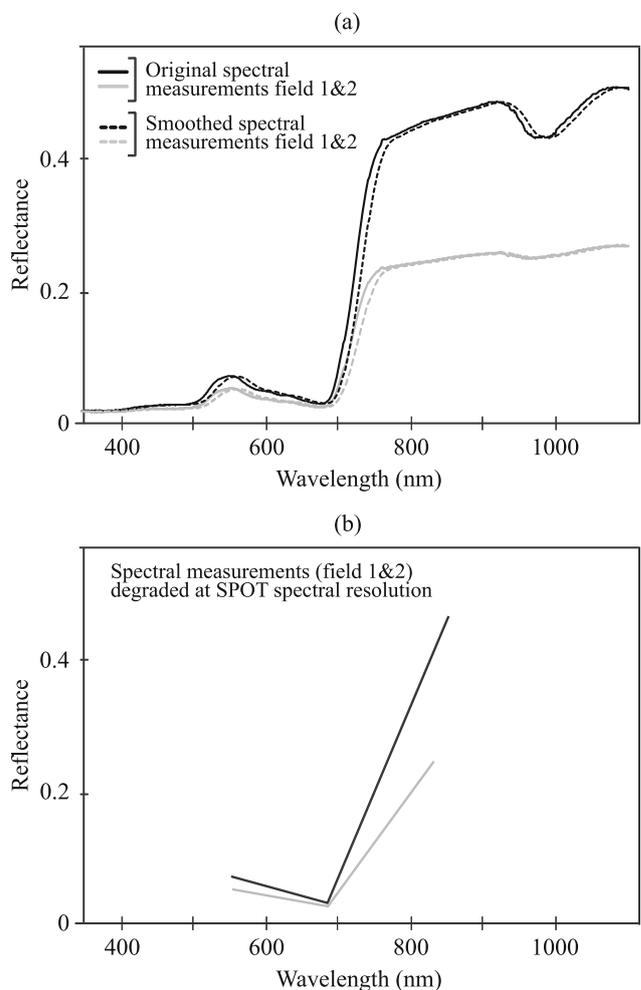


**Fig. 3** Classification of grassland surface conditions into three statuses: crop height of less than 10 cm with soil visible (coverage rate <70 %) (status 1) (a), crop height between 10 and 20 cm (coverage rate >90 %) (status 2) (b), and crop height greater than 20 cm (coverage rate=100 %) (status 3) (c)

Spectrometry preprocessing

Several processing steps were performed in order to study and use field spectrometer measurements (Fig. 4): spectrometer measurements were transformed (cleaned, smoothed, and averaged) to be sorted by surface condition. Moreover, to compare field spectrometer measurements to remote sensing data, NDVI was computed from spectrometer measurements.

Firstly, the reflectance spectra were too noisy in the wavelengths in which the atmospheric water absorbs most incoming radiation. Therefore, bands from 1,350–1,450, 1,800–2,070, and 2,350–2,500 nm were excluded (Fig. 4a). Then, in order to compare field data to remote sensing data, only information in the visible



**Fig. 4** Workflow of processing steps of the spectral profiles collected in the fields (example of one profile for a crop height higher than 20 cm and of one profile for a crop height smaller than 10 cm): smoothing of original spectral measurements (a) and spectral measurements degraded at SPOT spectral resolution (b)

and near-infrared wavelengths was retained (dashed line in Fig. 4a).

Secondly, the ten spectrometer measurements collected per field were averaged to obtain a single spectral signature that covers the range of radiometric variation within the field (Fig. 4b).

Thirdly, spectral profiles were smoothed to remove artefacts by applying a 20-nm wide simple moving average (SMA) (Fig. 4c). The SMA was calculated by averaging a selected number of values on each side of the target data. The SMA corresponds to the unweighted mean of the previous  $x$  data points, i.e., 20 data points in our case. If these data points are  $vM$ ,  $vM - 1, \dots, vM - (x - 1)$ , then the formula is:

$$\text{SMA} = \frac{vM + (vM - 1) + \dots + (vM - (x - 1))}{x} \quad (1)$$

where  $x$  is the number of value to average.

Then, spectral measurements were resampled from 1 nm (spectroradiometer, 2,150 spectral bands from 350 to 2,500 nm) to approximately 100 nm, corresponding to the SPOT spectral bands (Fig. 4d), in order to compare spectral signatures extracted from field campaigns and SPOT images. The resample of the spectroradiometer data was realized in calculating the mean reflectance value corresponding to each spectral band of the SPOT sensor [0.45–0.52  $\mu\text{m}$  (blue), 0.52–0.60  $\mu\text{m}$  (green), 0.63–0.69  $\mu\text{m}$  (red)].

Finally, a vegetation index widely used to monitor vegetation cover (Wang et al. 2005; Fontana et al. 2008), namely the NDVI (Rouse et al. 1974), was derived from the spectral reflectance profiles. NDVI is calculated as the near-infrared minus red reflection divided by the sum of the two.

#### Hemispherical photograph preprocessing

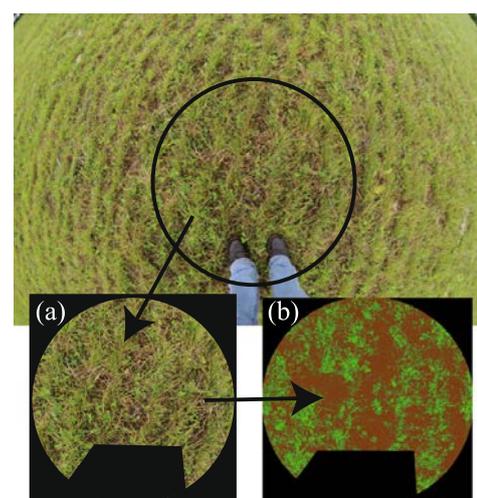
LAI and fCOVER values were computed from the digital hemispherical photographs (DHP) in RGB colors acquired during the field campaigns using CAN-EYE V6.1 software (Weiss and Baret 2010). Firstly, processing characteristics (optical center, projection function, angular resolution, and FAPAR computation) were defined according to camera and fish-eye lens characteristics, images configuration, and CAN-EYE-specific parameters. For more details about software parametrization refer to Weiss and Baret (2010). Secondly, some noisy images were removed, and parts of the images that

were not covered by vegetation or background (operator or undesired objects like roads or trees for example) were masked (Fig. 5a). Then, the selected images were classified into two categories, vegetation and soil background (vegetation is here defined as green vegetation, soil background including non-green and dried vegetation): the least represented class in the image was firstly selected, i.e., soil for dense canopies or vegetation for sparse canopies. Non-selected pixels were then automatically attributed to the second class, i.e., vegetation if the soil class was selected first or soil if the vegetation class was selected first. Finally, classified images were used to compute the output variables LAI and fCOVER (Fig. 5b). These biophysical variables were derived from the bi-directional gap fraction measured from the hemispherical images as detailed in Garrigues et al. (2008) and Weiss et al. (2004).

#### Remote sensing image preprocessing

The first step was to correct satellite images from radiometric and atmospheric effects. These corrections were performed applying the 6S model (second simulation of a satellite signal in the solar spectrum vector code) developed by Vermote et al. (1997).

In a second step, the geometric correction was undertaken using ArcGIS 10. All data were georeferenced based on the Lambert 2 conformal conic system and the root mean square error being less than one pixel. Images



**Fig. 5** Processing steps of the hemispherical photographs collected in the fields (example on one photograph for a crop height of less than 10 cm with soil visible): Mask step (a) and classification step (b)

were resampled using the nearest neighbor method which does not change the pixel values.

Then, the NDVI was calculated according to Rouse et al. (1974), and biophysical variables (LAI and fCOVER) were retrieved from satellite images using the PROSAIL radiative transfer model which combines the SAIL and PROSPECT models (Jacquemoud et al. 2009; Jacquemoud and Baret 1990a; Verhoef 1984). The prior distribution of all input variables required to simulate and train the PROSAIL model is described by Dusseux et al. (2014). These parameters were defined according to the original CYCLOPES parameterization (Baret et al. 2007) and references available on the subject (Lecerf et al. 2008; Feret et al. 2008; Weiss et al. 2000; Claverie et al. 2013; Duveiller et al. 2011; Bsaibes et al. 2009; Soudani et al. 2006).

Finally, based on ground measurements, NDVI, LAI, and fCOVER values were selected in the 20 collected fields according to the three surface condition classes previously detailed (S1, S2, and S3).

*Dissimilarity metric*

Before the realization of the statistical analysis and the comparison of spectra and extracted variables, data were normalized using the standard score to obtain independent data units. The standard value of a raw score  $x$  is:

$$z = \frac{x - \mu}{\sigma} \tag{2}$$

where  $\mu$  is the mean of the concerned variables and  $\sigma$  is the standard deviation of the concerned variables. Thus, a centered and reduced variable has a mean equal to 0 and a standard deviation equal to 1.

Then, in order to quantify the variation between measurements and to compare values of different surface conditions, a dissimilarity metric  $D$  was computed as follows:

$$D = \sqrt{\sum_{i=1}^n |x_i - y_i|^2} \tag{3}$$

The dissimilarity metric  $D$  is the Euclidean distance between two spectra or values,  $x_i$  and  $y_i$ . This metric is used to obtain a quantitative discrimination between spectra and variables. As the Euclidean distance increases, measurements are increasingly dissimilar.

*Data classification*

The data used in this study, i.e., the parameters estimated from the ASD spectroradiometer, hemispherical photographs, and SPOT images, were classified using two classification approaches: the K-means unsupervised algorithm (MacQueen 1967) and the K-Nearest Neighbor (KNN) supervised algorithm (Cover and Hart 1967).

The classification of the profiles estimated from the three data sources was first performed with both classifiers using data on grassland management collected from a sample of seven fields to (1) comparatively estimate the profile separability of the data sources and (2) evaluate the performance of the classification approach.

The supervised KNN algorithm was then used to classify SPOT image profiles using different available samples to evaluate the impact of the sample size on the classification precision. After having performed the classification of the 102 fields for which information on vegetation and agricultural practices was collected on the basis of the smallest sample (seven fields), the classification was applied to the whole study site (around 3,000 fields) using the largest sample (102 profiles classified in the preceding step).

In all cases, the Kappa index ( $K$ ), commonly used for the assessment of prediction errors, was used to evaluate classification accuracy (Congalton 1991). Its significance was assessed with the chi-squared test.

**Results and discussion**

*Data analysis*

*Spectroradiometric profiles (similarity and dissimilarity) and NDVI values derived*

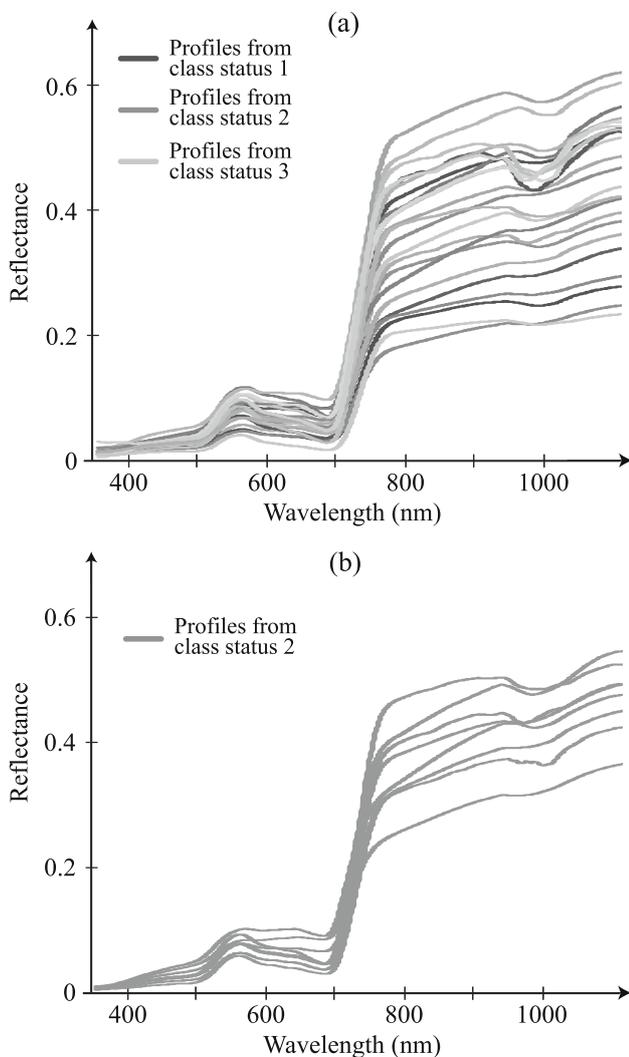
Most of the spectral profiles derived from field spectrometer measurements are similar in the shape but appeared separable on the basis of amplitude (Fig. 6a). However, according to Price (1994), within vegetation state reflectance spectra, there can be variation in spectral measurements. Different vegetation states may correspond to spectra with similar values, whereas one given vegetation state can be represented by quite different spectral profiles (Price 1994). The variability of

the spectral reflectance within a class of the same grassland surface condition is illustrated by Fig. 6b.

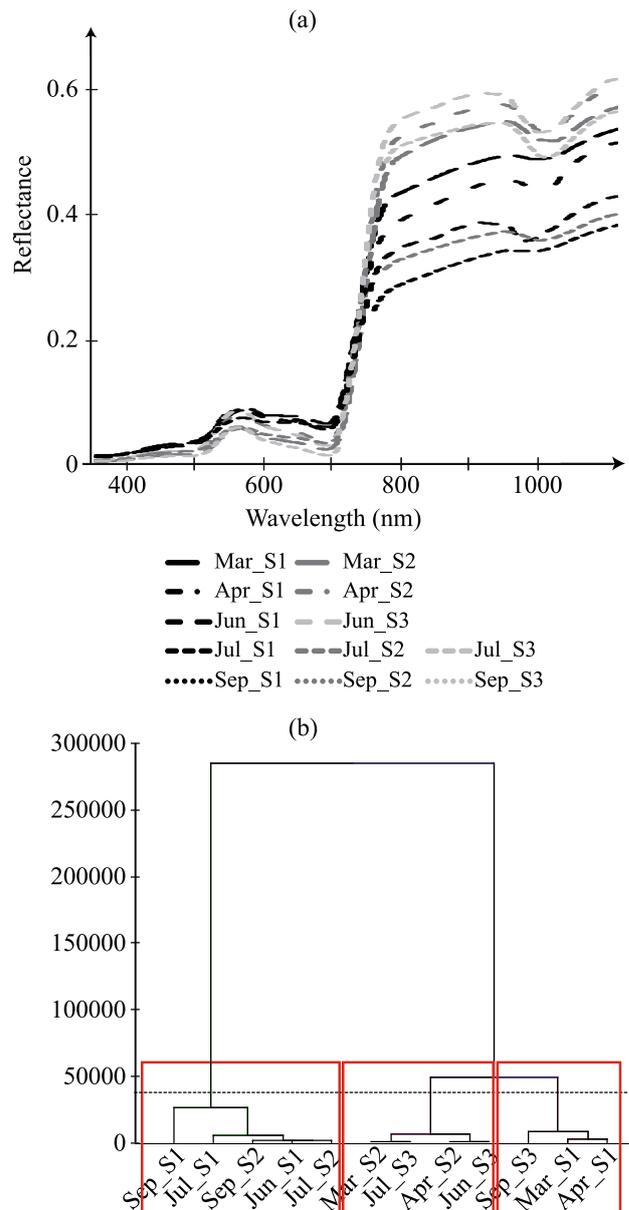
In order to study the relationship between spectral measurements and satellite images, spectrometer measurements were listed and compared by month and by type of surface condition (Fig. 7a). We observed that by month, spectral profiles for status 1 have higher reflectance values in the visible and lower reflectance values in the near infrared (NIR) than spectral profiles for status 2 and status 3; this is due to the spectral contribution of the soil (Jensen 2000). The classification of spectral measurements was achieved using a Hierarchical Ascendant Classification (HAC, Ward methods) to show spectral differences from 1 month to another according to the plot surface condition (Fig. 7b). The main objective was to separate spectral profiles into

homogeneous classes that minimize intra-class variability and increase inter-class differences. The distribution of spectral profiles according to the HAC (Fig. 7b) shows high intra-class variability. One can also observe that some spectral profiles of the different statuses were aggregated in the same class using the HAC, which could explain image misclassifications.

The NDVI was then calculated from spectral measurements degraded at SPOT spectral resolution and sorted by surface condition (Table 2). NDVI values for status 1 are lower than NDVI values for status 2, which



**Fig. 6** Spectral profiles from ASD FieldSpec3 spectrometer: **a** similarity in shape between spectral profiles; **b** variability within a class of same grassland surface condition



**Fig. 7** Spectrometer profiles classified per month and according to surface condition **(a)** and result of Hierarchical Ascendant Classification on spectrometer profiles (S1 status 1, S2 status 2, and S3 status 3) **(b)**

**Table 2** Mean NDVI estimated from spectral measurements per class and per month

NDVI	Status 1	Status 2	Status 3
11 March 2010	0.71	0.85	–
21 April 2010	0.72	0.81	–
15 June 2010	0.68	–	0.83
07 July 2010	0.66	0.77	0.89
21 September 2010	0.58	0.67	0.73

are in turn lower than NDVI values for status 3. Indeed, this index provides information on the vegetation status and it increases with the fractional vegetation cover.

*LAI and fCOVER estimated from hemispherical photographs*

As for spectral measurements, mean LAI and fCOVER values estimated from hemispherical photographs were listed by surface condition (Table 3). We observed that LAI and fCOVER values are correlated with the vegetation height. Indeed, values of class status 1 are lower than values of class 2 that are in turn lower than values of class 3. LAI values that are used as a reference indicator for vegetation

**Table 3** Mean LAI and fCOVER estimated from hemispherical photographs per class and per month

	Status 1	Status 2	Status 3
<b>LAI</b>			
11 March 2010	1.5	3.4	–
26 May 2010	1.2	3.1	6.1
15 June 2010	2	3.4	5.4
07 July 2010	2.1	3.4	5
02 August 2010	1.9	3.6	5.7
21 September 2010	–	2.6	5.5
08 November 2010	1.7	3	4.9
<b>fCOVER</b>			
11 March 2010	0.6	0.87	–
26 May 2010	0.58	0.85	0.99
15 June 2010	0.7	0.84	0.91
07 July 2010	0.76	0.84	0.92
02 August 2010	0.78	0.84	0.97
21 September 2010	–	0.81	0.96
08 November 2010	0.8	0.82	0.97

growth are directly correlated with vegetation height and canopy density (Weiss et al. 2004).

*Remote sensing images and estimated variables*

As for spectral measurements and hemispherical photographs, training sets associated with the three satellite images were sorted by surface condition (Fig. 8). We observe that status 1 profiles have higher reflectance values in the visible and lower reflectance values in the near infrared compared to status 2 and 3 profiles; this is due to the spectral contribution of the soil (Jensen 2000). Furthermore, the spectral difference observed in the field profiles for the three statuses largely disappeared in the image profiles in the first two visible spectral bands while it remained quite significant in the NIR.

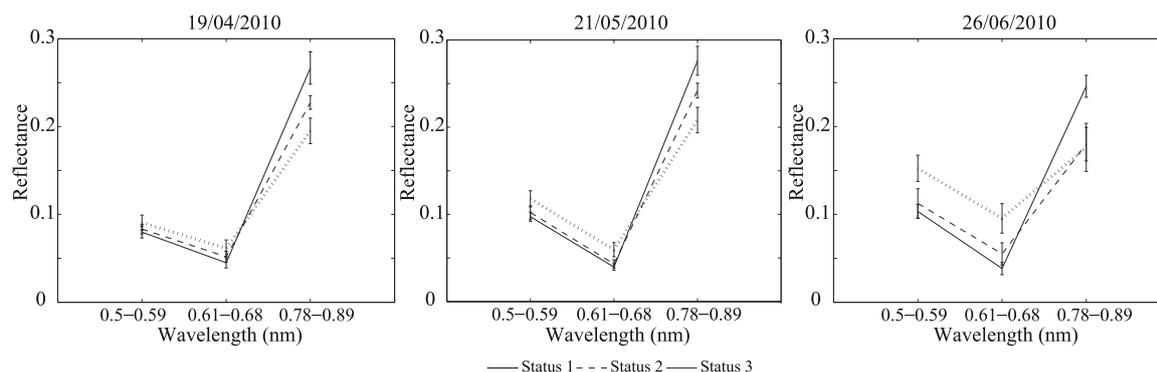
Mean NDVI, LAI, and fCOVER values are derived from these spectral profiles (Table 4).

Statistical analysis

The *D* values between classes with different grassland surface condition per month were calculated and are presented in Table 5 for NDVI derived from spectrometer profiles, in Table 6 for LAI and fCOVER estimated from hemispherical photographs, and in Table 7 for NDVI, LAI, and fCOVER derived from remotely sensed images.

*D* values ranged from 0 to 1 for very similar values and were greater than 1 for dissimilar values. Generally, *D* is higher between classes for statuses 1 and 3 due to the differences between the surface conditions of these two classes. Moreover, NDVI and fCOVER variables show greater dissimilarity between classes for statuses 1 and 2 and between classes for statuses 1 and 3, while LAI variables show greater dissimilarity between classes for statuses 2 and 3 and between classes for statuses 1 and 3.

Therefore, concerning LAI and fCOVER variables estimated from hemispherical photographs, May appears to show as the greatest dissimilarity between classes. This is confirmed by *D* values from LAI derived from satellite images, but not with fCOVER values. Concerning fCOVER and NDVI variables, the month of June is the best time of that particular year to distinguish grassland management practices. However, this can vary from 1 year to another according to climate condition and phenological stages.



**Fig. 8** Mean spectral profiles derived from satellite images and classified according to surface condition

Comparison of observed and remotely sensed variables

Surface conditions

The comparison of the variables NDVI, LAI, and fCOVER estimated from field measurements and from SPOT images shows that the values estimated are not similar. Indeed, we can observe that NDVI values calculated from field measurements were generally higher than NDVI values calculated from SPOT images (comparison of Tables 2 and 4). The same observation can be made for fCOVER values derived from hemispherical photographs and SPOT images (comparison of Tables 3 and 4).

Relationships between (a) NDVI values estimated from SPOT images ( $NDVI_{spot}$ ) and from spectral measurements ( $NDVI_{spectral}$ ), (b) LAI values estimated from SPOT images ( $LAI_{spot}$ ) and from hemispherical photographs ( $LAI_{hemis}$ ), and (c) fCOVER values estimated

from SPOT images ( $fCOVER_{spot}$ ) and from hemispherical photographs ( $fCOVER_{hemis}$ ) were examined (Fig. 9). A linear relationship was observed between  $NDVI_{spot}$  and  $NDVI_{spectral}$  values, between  $LAI_{spot}$  and  $LAI_{hemis}$  values, and between  $fCOVER_{spot}$  and  $fCOVER_{hemis}$  values. The LAI variable shows a higher relationship ( $R^2=0.94$ ) than the NDVI variable ( $R^2=0.90$ ) and the fCOVER variable ( $R^2=0.77$ ). Moreover,  $NDVI_{spectral}$  and  $fCOVER_{hemis}$  values are mostly higher than  $NDVI_{spot}$  and  $fCOVER_{spot}$  values, which lead to a decrease in the correlation index.

The NDVI index is sensitive to the soil contribution and to the atmosphere (Montandon and Small 2008; Henebry 1993; Baret and Guyot 1991). Moreover, several studies have shown that NDVI values, which are calculated from measures in the visible and near infrared wavebands, depend on sensor characteristics (spectral bands width, orbital position, etc.) and the recording system (Jiang et al. 2006; Franke et al. 2006; Jacquemoud and Baret 1990b; Baret et al. 1989). Several studies have also demonstrated non-linear relationships between NDVI and vegetation properties and LAI (Edirisinghe et al. 2011; Viña et al. 2011; Huete et al. 1985; Carlson and Ripley 1997). According to Huete et al. (1997), the relationship is poor during periods of maximum LAI, apparently due to the

**Table 4** Mean NDVI, LAI, and fCOVER estimated from SPOT images per class and per month

	Status 1	Status 2	Status 3
<b>NDVI</b>			
19 April 2010	0.52	0.63	0.71
21 May 2010	0.55	0.7	0.75
26 June 2010	0.3	0.53	0.73
<b>LAI</b>			
19 April 2010	0.7	1.3	2.4
21 May 2010	1.5	2.8	5.3
26 June 2010	1.3	3	4.7
<b>fCOVER</b>			
19 April 2010	0.51	0.68	0.72
21 May 2010	0.43	0.72	0.83
26 June 2010	0.39	0.72	0.85

**Table 5** Values of dissimilarity metric *D* for NDVI derived from spectrometer profiles between the three status classes

NDVI	S1-S2	S2-S3	S1-S3
11 March 2010	0.6	–	–
21 April 2010	1	–	–
15 June 2010	–	–	2.9
07 July 2010	1.6	1.9	7
21 September 2010	1	0.5	2.9

**Table 6** Values of dissimilarity metric *D* for LAI and fCOVER estimated from hemispherical photographs between the three status classes

	S1-S2	S2-S3	S1-S3
<b>LAI</b>			
11 March 2010	1.3	–	–
26 May 2010	1.5	4.8	11.6
15 June 2010	0.8	1.5	4.4
07 July 2010	0.7	0.9	3.1
02 August 2010	1	1.7	5.3
21 September 2010	–	3.1	–
08 November 2010	0.6	1.5	4
<b>fCOVER</b>			
11 March 2010	4.7	–	–
26 May 2010	5.6	1.5	13
15 June 2010	1.7	0.4	3.6
07 July 2010	0.5	0.4	1.8
02 August 2010	0.3	1.4	3
21 September 2010	–	1.8	–
08 November 2010	0	2.2	2.2

saturation of NDVI over densely vegetated areas. In addition, it was shown that for a vegetation cover rate above 60 %, vegetation indices using the NIR channel are insensitive to changes related to vegetation (Gitelson et al. 2002; Glenn et al. 2008; Wu et al. 2007; Diaz and Blackburn 2003). Thus, the difference in accuracy between vegetation indices and biophysical variables to

**Table 7** Values of dissimilarity metric *D* for NDVI, LAI, and fCOVER estimated from SPOT images between the three status classes

	S1-S2	S2-S3	S1-S3
<b>NDVI</b>			
19 April 2010	0.58	0.3	1.7
21 May 2010	1	0.1	1.9
26 June 2010	2.5	1.9	8.9
<b>LAI</b>			
19 April 2010	0.1	0.5	1.1
21 May 2010	0.7	2.5	5.7
26 June 2010	1.1	1.1	4.6
<b>fCOVER</b>			
19 April 2010	1	0.1	1.6
21 May 2010	3	0.4	5.7
26 June 2010	3.9	0.6	7.6

discriminate vegetation state is explained by the sensitivity of vegetation indices to disturbances related to the optical properties of the soil unlike biophysical variables. For example, LAI and fCOVER provide information on the vegetation density and cover, respectively (Jacquemoud et al. 2009; Lecerf et al. 2008). Indeed, low LAI and high fCOVER values encountered in a given field can reveal a sparse, emerging, or senescent vegetation cover. Therefore, LAI values can be used to evaluate the density of green vegetation and identify corresponding agricultural practices. For example, cut grasslands are characterized, before the harvest, by high grass cover and high greenness, i.e., higher LAI values compared to grazed grasslands. Considering these observations, we decided to use the LAI variable in this study as an indicator to monitor grassland management practices.

*Agricultural practices*

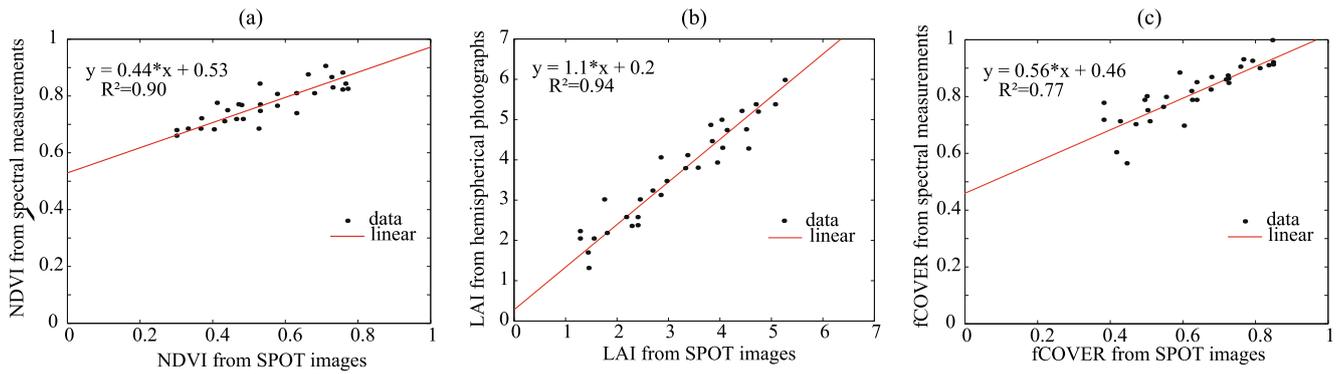
As recalled previously, three types of grassland management practices were identified: grazing, mowing, and mixed management that combines both methods during the vegetation season. Vegetation surface conditions vary with these management practices. Thus, temporal profiles of LAI values can be used to identify and classify grassland management practices.

- Comparison of classifications performed from LAI estimated from DHP and LAI derived from SPOT images

The training set used was composed of the LAI temporal profiles extracted in 7 fields selected from the 20 fields observed during the field campaigns. Field measurements were continuous during the season on seven fields; thus, only these fields were retained for the classification step. Figure 10 shows various time series of LAI for the three classes, as well as the mean and intra-class variance over time of the LAI according to the three management practices for these seven fields.

From these graphs, it can be seen that:

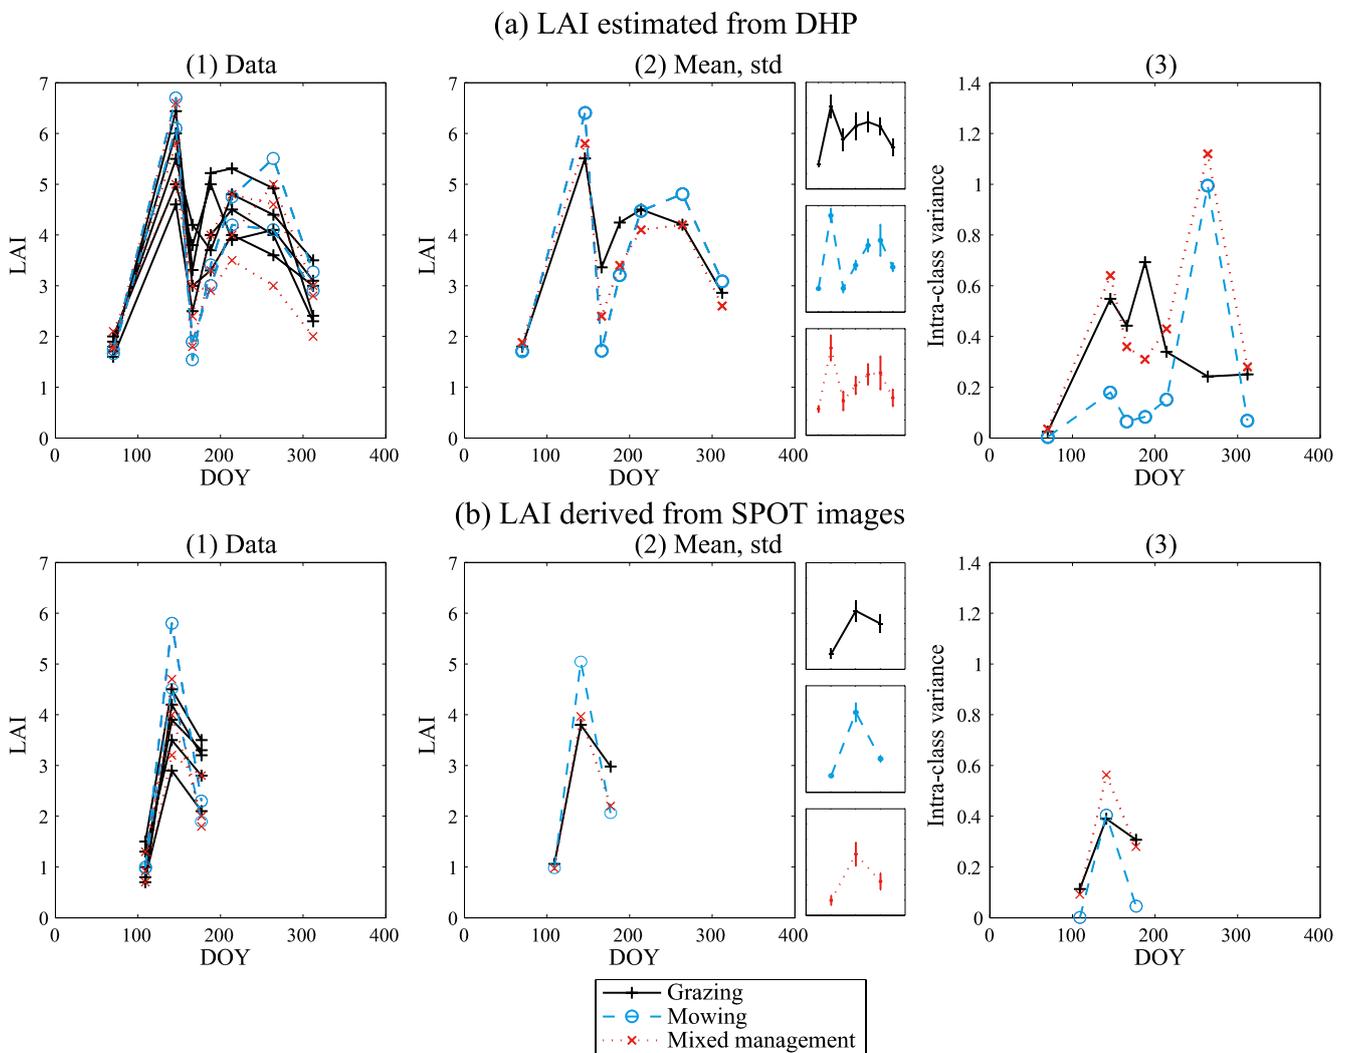
- For LAI estimated from DHP (time series with seven data points per profile), grazing and mowing practices show dissimilar behavior especially in May (DOY: 146) and June (DOY: 166) [Fig. 10a(2)]. This can be explained by different surface conditions (crop height and biomass)



**Fig. 9** Simple linear regression between mean NDVI values estimated from SPOT images ( $NDVI_{spot}$ ) and mean NDVI values estimated from spectral measurements ( $NDVI_{spectral}$ ) (a), between mean LAI values estimated from SPOT images ( $LAI_{spot}$ ) and mean LAI values estimated from hemispherical photographs ( $LAI_{hemis}$ ) (b), between mean fCOVER values estimated from SPOT images ( $fCOVER_{spot}$ ) and mean fCOVER values estimated from hemispherical photographs ( $fCOVER_{hemis}$ ) (c)

generated by these two management practices being more visible at this period. In addition, while the LAI temporal profiles for the grazing and the mixed

management practices exhibited more dispersion around the average (data are spread out over a large range of LAI values), they show low standard



**Fig. 10** a LAI values estimated from DHP (1), mean (2), and intra-class variance (3). b LAI values derived from SPOT images (1), mean (2), and intra-class variance (3)

deviation (intra-class variance) for mowing except in September (DOY: 264) [Fig. 10a(3)].

- b. Concerning LAI values derived from SPOT images (time series with three values per profile), grazing and mowing practices show dissimilar behavior especially in May (DOY: 141) [Fig. 10b(2)]. In addition, LAI time series of the three classes of practices show very low standard deviation for April (DOY: 109) and June (DOY: 177) and low standard deviation in May (DOY: 141) [Fig. 10b(3)].

Thus, some differences between classes can be observed for LAI values estimated from DHP and derived from SPOT images, but achieving perfect discrimination between all classes is no simple task. Grazing and mowing show different profiles, while mixed management can be confused with the two previous classes. Thus, according to the number and acquisition dates of available remote sensing data, only grazing and mowing could be classified in a reliable way. Indeed, LAI profiles derived from SPOT images illustrate the first period of grassland management, and mixed management could not be identified. Therefore, only grazing and mowing were considered for the classification process. Grazing and mowing are discriminated with, respectively, 0.7 and 0.6 of accuracy (Kappa index) for LAI estimated from DHP ( $p$  value=0.02) and LAI derived from SPOT images ( $p$  value=0.03).

This difference can be explained by the fact that the profiles derived from SPOT images were defined with only three LAI values while seven values were obtained from hemispherical photograph profiles (DHP). Thus, logically, the higher the number of points used to construct the temporal profile of LAI, the more accurate the identification of agricultural practices applied to grassland management. The difference could also be explained by the fact that the classification method applied did not take into account any a priori knowledge. This non-supervised classification method is not suitable for the classification of LAI profiles for classes which are very close one another. To improve the results, we applied a supervised classification method (KNN) to discriminate LAI profiles constructed from SPOT images. The results obtained with the supervised classification method were better since the kappa index is 0.7, but they still cannot be considered satisfactory. However, the sample used to train and validate the classifications obtained from the hemispherical photographs and the SPOT images is limited since the first were only available for seven plots. As we collected

measurements in 120 fields, we decided to extend the sample used to classify the SPOT images over the whole watershed that contains 3,000 grasslands to get a better classification result on this scale.

- Comparison of classifications derived from remote sensing data and observed practices

First, a supervised classification was performed on LAI derived from SPOT images for the 102 fields where information on vegetation and agricultural practices was collected (Fig. 11b). We obtained a kappa index of 0.83 ( $p$  value <0.005).

These fields were used as a training set to perform the classification of all LAI profiles derived from SPOT images of the study site (Fig. 11c). We obtained here a kappa index of 0.82 ( $p$  value <0.005).

A kappa index higher than 0.8 is considered as a good result; thus, our classification results are now good. With such data, we can differentiate grazed and cut grasslands with more than 80 % accuracy. However, phenology stages can be different from 1 year to another according to climate condition and thus grassland management practices can be shifted in time during the growth period. Thereby, the discrimination of grassland management practices is dependent to image acquisition dates. Figure 12, which illustrates the spatial distribution of these two types of grassland management at the watershed scale, shows that grazing is the predominant use on the studied area, which was confirmed by the information collected during field campaigns, and expert knowledge from the Acassya program (Moreau et al. 2012). Thus, a quite simple classification based on satellite images such as SPOT can discriminate two of the three types of grassland management practices. However, for mixed management, a higher number of satellite images is needed during the vegetation season to identify specific LAI temporal patterns close to those characteristics of isolated mowing and grazing practices (Griffith et al. 2001).

## Conclusion

The aim of this paper was to assess the relationship between variables estimated from a series of SPOT images and field data in order to identify agricultural practices applied on grasslands. To do so, we analyzed the performances of time series of remote sensing

	(a)		(b)		(c)																																																																																																																							
<b>Classification method</b>	Unsupervised classification: K-means		Supervised classification: K-nearest neighbor		Supervised classification: K-nearest neighbor																																																																																																																							
<b>Data to classify</b>	LAI estimated from DHP: 7 fields	LAI derived from SPOT images: 7 fields	LAI derived from SPOT images: Around 100 fields (Field campaigns data)		LAI derived from SPOT images: Study site (Around 2000 fields)																																																																																																																							
<b>Training set (Ground-truth data)</b>	-	-	LAI derived from SPOT images: 7 fields		LAI derived from SPOT images: 60 fields (Around 2/3 of field campaigns data)																																																																																																																							
<b>Validation set</b>	LAI estimated from DHP: 7 fields	LAI derived from SPOT images: 7 fields	LAI derived from SPOT images: Around 100 fields (Field campaigns data)		LAI derived from SPOT images: 42 fields (Around 1/3 of field campaigns data)																																																																																																																							
<b>Confusion matrix</b>	<table border="1"> <thead> <tr> <th colspan="2"></th> <th>Classification 1</th> <th>Classification 2</th> <th>T1</th> <th>Error O</th> </tr> </thead> <tbody> <tr> <th rowspan="2">Ground-truth data</th> <th>1</th> <td>4</td> <td>1</td> <td>5</td> <td>0.2</td> </tr> <tr> <th>2</th> <td>0</td> <td>2</td> <td>2</td> <td>0</td> </tr> <tr> <th colspan="2">T2</th> <td>4</td> <td>3</td> <td>7</td> <td></td> </tr> <tr> <th colspan="2">Error C</th> <td>0</td> <td>0.5</td> <td></td> <td></td> </tr> </tbody> </table>				Classification 1	Classification 2	T1	Error O	Ground-truth data	1	4	1	5	0.2	2	0	2	2	0	T2		4	3	7		Error C		0	0.5			<table border="1"> <thead> <tr> <th colspan="2"></th> <th>Classification 1</th> <th>Classification 2</th> <th>T1</th> <th>Error O</th> </tr> </thead> <tbody> <tr> <th rowspan="2">Ground-truth data</th> <th>1</th> <td>5</td> <td>0</td> <td>5</td> <td>0</td> </tr> <tr> <th>2</th> <td>1</td> <td>1</td> <td>2</td> <td>0.5</td> </tr> <tr> <th colspan="2">T2</th> <td>6</td> <td>1</td> <td>7</td> <td></td> </tr> <tr> <th colspan="2">Error C</th> <td>0.2</td> <td>0</td> <td></td> <td></td> </tr> </tbody> </table>				Classification 1	Classification 2	T1	Error O	Ground-truth data	1	5	0	5	0	2	1	1	2	0.5	T2		6	1	7		Error C		0.2	0			<table border="1"> <thead> <tr> <th colspan="2"></th> <th>Classification 1</th> <th>Classification 2</th> <th>T1</th> <th>Error O</th> </tr> </thead> <tbody> <tr> <th rowspan="2">Ground-truth data</th> <th>1</th> <td>76</td> <td>2</td> <td>78</td> <td>0.02</td> </tr> <tr> <th>2</th> <td>4</td> <td>20</td> <td>24</td> <td>0.16</td> </tr> <tr> <th colspan="2">T2</th> <td>80</td> <td>22</td> <td>102</td> <td></td> </tr> <tr> <th colspan="2">Error C</th> <td>0.05</td> <td>0.08</td> <td></td> <td></td> </tr> </tbody> </table>				Classification 1	Classification 2	T1	Error O	Ground-truth data	1	76	2	78	0.02	2	4	20	24	0.16	T2		80	22	102		Error C		0.05	0.08			<table border="1"> <thead> <tr> <th colspan="2"></th> <th>Classification 1</th> <th>Classification 2</th> <th>T1</th> <th>Error O</th> </tr> </thead> <tbody> <tr> <th rowspan="2">Ground-truth data</th> <th>1</th> <td>34</td> <td>0</td> <td>34</td> <td>0</td> </tr> <tr> <th>2</th> <td>2</td> <td>6</td> <td>8</td> <td>0.75</td> </tr> <tr> <th colspan="2">T2</th> <td>36</td> <td>6</td> <td>42</td> <td></td> </tr> <tr> <th colspan="2">Error C</th> <td>0.05</td> <td>0</td> <td></td> <td></td> </tr> </tbody> </table>				Classification 1	Classification 2	T1	Error O	Ground-truth data	1	34	0	34	0	2	2	6	8	0.75	T2		36	6	42		Error C		0.05	0		
			Classification 1	Classification 2	T1	Error O																																																																																																																						
Ground-truth data	1	4	1	5	0.2																																																																																																																							
	2	0	2	2	0																																																																																																																							
T2		4	3	7																																																																																																																								
Error C		0	0.5																																																																																																																									
		Classification 1	Classification 2	T1	Error O																																																																																																																							
Ground-truth data	1	5	0	5	0																																																																																																																							
	2	1	1	2	0.5																																																																																																																							
T2		6	1	7																																																																																																																								
Error C		0.2	0																																																																																																																									
		Classification 1	Classification 2	T1	Error O																																																																																																																							
Ground-truth data	1	76	2	78	0.02																																																																																																																							
	2	4	20	24	0.16																																																																																																																							
T2		80	22	102																																																																																																																								
Error C		0.05	0.08																																																																																																																									
		Classification 1	Classification 2	T1	Error O																																																																																																																							
Ground-truth data	1	34	0	34	0																																																																																																																							
	2	2	6	8	0.75																																																																																																																							
T2		36	6	42																																																																																																																								
Error C		0.05	0																																																																																																																									
<b>Kappa index</b>	0.7		0.6		0.83																																																																																																																							
<b>p-value</b>	0.02		0.03		<0.005																																																																																																																							

Fig. 11 Classification process and Kappa results

images. Field campaigns were conducted to collect monthly data on vegetation status and grassland

management. In the same period, three SPOT images were acquired during the growing season. A vegetation



Fig. 12 Spatial distribution of grassland agricultural practices on the Yar watershed

index, namely the Normalized Difference Vegetation Index (NDVI), and two biophysical variables, the Leaf Area Index (LAI) and the fraction of Vegetation Cover (fCOVER), were computed both from field data and satellite images. These variables were processed in order to compare those derived from field measurements and from satellite images for vegetation state identification (Weiss et al. 2004; Price 1998). The analysis of the relationship between these variables shows that the LAI was proven to be the best predictor to identify grassland mowing and grazing during the growing season. Indeed, because of its ability to characterize vegetation status, the LAI estimated from satellite images is a relevant variable to identify these practices over large agricultural areas. Moreover, it was shown that grassland practices such as grazed vs cut grasslands could be discriminated using a series of three satellite images. When these two practices are applied successively during the growing season, a higher number of satellite images have to be used to identify them. Moreover, the application of the approach developed in this study on a time series constructed with images acquired by Sentinel-2 or Venus future sensors is expected to describe the intensity of these practices and to identify other farming practices such as fertilization and grassland composition (pure grass or legumes, grass legumes mixture, and plurispesific grasslands).

**Acknowledgments** This work was supported by the ANR SYSTERRA-ACASSYA program (ANR-08-STRA-01). We also want to thank the CNES for providing us with the satellite images, Sally Ferguson for revising the manuscript, and the anonymous referees for their valuable comments.

## References

- Arrouays, D., Deslais, W., & Bateau, V. (2001). The carbon content of topsoil and its geographical distribution in France. *Soil Use and Management*, 17(1), 7–11.
- Asam, S., Fabritius, H., Klein, D., Conrad, C., & Dech, S. (2013). Derivation of leaf area index for grassland within alpine upland using multi-temporal rapid eye data. *International Journal of Remote Sensing*, 34(23), 8628–8652. doi:10.1080/01431161.2013.845316.
- ASD. (2000). *FieldSpec 3 portable spectroradiometer user's guide*. Colorado: Analytical Spectral Devices.
- Baret, F., & Guyot, G. (1991). Potentials and limits of vegetation indices for LAI and APAR assessment. *Remote Sensing of Environment*, 35, 161–173.
- Baret, F., Guyot, G., & Major, D. (1989). TSAVI: a vegetation index which minimizes soil brightness effects on LAI and APAR estimation. In: Proceedings of the 12th Canadian Symposium on Remote Sensing and IGARSS'89, Cairo, Egypt, vol 3, pp. 1355–1358.
- Baret, F., Hagolle, O., Geiger, B., Bicheron, P., Miras, B., Huc, M., Berthelot, B., Niño, F., Weiss, M., Samain, O., Roujean, J. L., & Leroy, M. (2007). LAI, fAPAR and fCover CYCLOPES global products derived from VEGETATION: part 1: principles of the algorithm. *Remote Sensing of Environment*, 110(3), 275–286. doi:10.1016/j.rse.2007.02.018. URL <http://www.sciencedirect.com.gate3.inist.fr/science/article/B6V6V-4NKJ1K0-1/2/29e421e7954752424d9bfb9b697ca68>.
- Batáry, P., Báldi, A., & Erdős, S. (2007). Grassland versus non-grassland bird abundance and diversity in managed grasslands: local, landscape and regional scale effects. *Biodiversity and Conservation*, 16, 871–881.
- Bsaibes, A., Courault, D., Baret, F., Weiss, M., Oliosio, A., Jacob, F., Hagolle, O., Marloie, O., Bertrand, N., Desfond, V., & Kzemipour, F. (2009). Albedo and LAI estimates from FORMOSAT-2 data for crop monitoring. *Remote Sensing of Environment*, 113(4), 716–729. doi:10.1016/j.rse.2008.11.014. URL <http://www.sciencedirect.com/science/article/pii/S0034425708003489>.
- Carlson TN, Ripley DA (1997) On the relation between NDVI, fractional vegetation cover, and leaf area index. *Remote Sensing of Environment* 62(3):241–252, DOI 10.1016/S0034-4257(97)00104-1. <http://www.sciencedirect.com/science/article/pii/S0034425797010104>
- Chen, J. M., & Black, T. A. (1991). Measuring leaf area index of plant canopies with branch architecture. *Agricultural and Forest Meteorology*, 57(1–3), 1–12.
- Claverie, M., Vermote, E. F., Weiss, M., Baret, F., Hagolle, O., & Demarez, V. (2013). Validation of coarse spatial resolution LAI and FAPAR time series over cropland in southwest France. *Remote Sensing of Environment*, 139, 216–230. doi:10.1016/j.rse.2013.07.027. URL <http://www.sciencedirect.com/science/article/pii/S0034425713002393>.
- Congalton, R. G. (1991). A review of assessing the accuracy of classifications of remotely sensed data. *Remote Sensing of Environment*, 37, 35–46.
- Corgne, S., Hubert-Moy, L., Barbier, J., & Solaiman, B. (2002). Follow-up and modeling of the land use in an intensive agricultural watershed in France. In: SPIE, 4879, Remote Sensing for Agriculture, Ecosystems, and Hydrology IV, pp. 342–351.
- Cover, T., & Hart, P. (1967). Nearest neighbor pattern classification. *IEEE Transactions on Information Theory*, 13(1), 21–27.
- Darvishzadeh, R., Atzberger, C., Skidmore, A., & Schlerf, M. (2011). Mapping grassland leaf area index with airborne hyperspectral imagery: a comparison study of statistical approaches and inversion of radiative transfer models. *ISPRS Journal of Photogrammetry and Remote Sensing*, 66(6), 894–906.
- Díaz, B. M., & Blackburn, G. A. (2003). Remote sensing of mangrove biophysical properties: evidence from a laboratory simulation of the possible effects of background variation on spectral vegetation indices. *International Journal of Remote Sensing*, 24(1), 53–73. doi:10.1080/01431160305012.
- Dusseux, P., Hubert-Moy, L., Lecerf, R., Corpetti, T., & Gong, X. (2011). Identification of grazed and mown grasslands using a

- time-series of high-spatial-resolution remote sensing images. In: 6th International Workshop on the Analysis of Multi-temporal Remote Sensing Images, Multitemp, Trento, Italy, pp. 145–148.
- Dusseux, P., Gong, X., Hubert-Moy, L., & Corpetti, T. (2014). Identification of grassland management practices from Lai time series. *Journal of Applied Remote Sensing*, In press.
- Duveiller, G., Weiss, M., Baret, F., & Defourny, P. (2011). Retrieving wheat green area index during the growing season from optical time series measurements based on neural network radiative transfer inversion. *Remote Sensing of Environment*, 115(3), 887–896. doi:10.1016/j.rse.2010.11.016. URL <http://www.sciencedirect.com/science/article/pii/S0034425710003354>.
- Edirisinghe, A., Hill, M. J., Donald, G. E., & Hyder, M. (2011). Quantitative mapping of pasture biomass using satellite imagery. *International Journal of Remote Sensing*, 32(10), 2699–2724. doi:10.1080/01431161003743181. URL <http://www.tandfonline.com/doi/abs/10.1080/01431161003743181>.
- Feret, J., François, C., Asner, G. P., Gitelson, A. A., Martin, R. E., Bidet, L. P., Ustin, S. L., le Maire, G., & Jacquemoud, S. (2008). PROSPECT-4 and 5: advances in the leaf optical properties model separating photosynthetic pigments. *Remote Sensing of Environment*, 112(6), 3030–3043.
- Fontana, F., Rixen, C., Jonas, T., Aberegg, G., & Wunderle, S. (2008). Alpine grassland phenology as seen in AVHRR, VEGETATION, and MODIS NDVI time series—a comparison with in situ measurements. *Sensors*, 8(4), 2833–2853.
- Franke, J., Heinzl, V., & Menz, G. (2006). Assessment of NDVI—differences caused by sensor specific relative spectral response functions. In: Proceedings of IEEE International Conference on Geoscience and Remote Sensing Symposium, IGARSS'06, pp 1138–1141. doi:10.1109/IGARSS.2006.294.
- Friedl, Michaelson, J., Davis, F. W., Walker, H., & Schimel, D. S. (1994). Estimating grassland biomass and leaf area index using ground and satellite data. *International Journal of Remote Sensing*, 15, 1401–1420.
- Gamon, J. A., Field, C. B., Goulden, M. L., Griffin, K. L., Hartley, A. E., Joel, G., Penuelas, J., & Valentini, R. (1995). Relationships between NDVI, canopy structure, and photosynthesis in three Californian vegetation types. *Ecological Applications*, 5(1), 28–41.
- Gao, F., Anderson, M. C., Kustas, W. P., & Wang, Y. (2012). Simple method for retrieving leaf area index from Landsat using MODIS leaf area index products as reference. *Journal of Applied Remote Sensing*, 6(1), 063,554-1. doi:10.1117/1.JRS.6.063554.
- Garrigues, S., Shabanov, N. V., Swanson, K., Morisette, J. T., Baret, F., & Myneni, R. B. (2008). Intercomparison and sensitivity analysis of leaf area index retrievals from LAI-2000, AccuPAR, and digital hemispherical photography over croplands. *Agricultural and Forest Meteorology*, 148(89), 1193–1209. doi:10.1016/j.agrformet.2008.02.014. URL <http://www.sciencedirect.com/science/article/pii/S0168192308000683>.
- Gitelson, A. A., Kaufman, Y. J., Stark, R., & Rundquist, D. (2002). Novel algorithms for remote estimation of vegetation fraction. *Remote Sensing of Environment*, 80(1), 76–87.
- Glenn, E. P., Huete, A. R., Nagler, P. L., & Nelson, S. G. (2008). Relationship between remotely-sensed vegetation indices, canopy attributes and plant physiological processes: what vegetation indices can and cannot tell us about the landscape. *Sensors*, 8(4), 2136–2160. doi:10.3390/s8042136.
- Griffith, J. A., Price, K. P., & Martinko, E. A. (2001). A multivariate analysis of biophysical parameters of tallgrass prairie among land management practices and years. *Environmental Monitoring and Assessment*, 68(3), 249–271.
- Guo, X., Price, K. P., & Stiles, J. M. (2000). Biophysical and spectral characteristics of cool- and warm-season grasslands under three land management practices in eastern Kansas. *Natural Resources Research*, 9(4), 321–331.
- Henebry, G. M. (1993). Detecting change in grasslands using measures of spatial dependence with landsat TM data. *Remote Sensing of Environment*, 46(2), 223–234.
- Huete, A. R., Jackson, R. D., & Post, D. F. (1985). Spectral response of a plant canopy with different soil backgrounds. *Remote Sensing of Environment*, 17(1), 37–53. doi:10.1016/0034-4257(85)90111-7. URL <http://www.sciencedirect.com/science/article/pii/0034425785901117>.
- Huete, A. R., Liu, H. Q., Batchily, K., & 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), 440–451. doi:10.1016/S0034-4257(96)00112-5. URL <http://www.sciencedirect.com/science/article/pii/S0034425796001125>.
- Huyghe, C., De Vlieghe, A., Van Gils, B., & Peeters, A. (2014). Grasslands and herbivore production in Europe and effects of common policies.
- Jacquemoud, S., & Baret, F. (1990a). PROSPECT: a model of leaf optical properties spectra. *Remote Sensing of Environment*, 34(2), 75–91.
- Jacquemoud, S., & Baret, F. (1990b). PROSPECT: a model of leaf optical properties spectra. *Remote Sensing of Environment*, 34(2), 75–91. doi:10.1016/0034-4257(90)90100-Z. URL <http://www.sciencedirect.com/science/article/pii/003442579090100Z>.
- Jacquemoud, S., Verhoef, W., Baret, F., Bacour, C., Zarco-Tejada, P., Asner, G., François, C., & Ustin, S. (2009). PROSPECT+SAIL models: a review of use for vegetation characterization. *Remote Sensing of Environment*, 113(Supplement 1), S56–S66.
- Jensen, J. R. (2000). *Remote sensing of the environment: an earth resource perspective*. Upper Saddle River: Prentice Hall.
- Jiang, Z., Huete, A. R., Chen, J., Chen, Y., Li, J., Yan, G., & Zhang, X. (2006). Analysis of NDVI and scaled difference vegetation index retrievals of vegetation fraction. *Remote Sensing of Environment*, 101(3), 366–378. doi:10.1016/j.rse.2006.01.003. URL <http://www.sciencedirect.com/science/article/pii/S0034425706000290>.
- Lecerf, R., Corpetti, T., Hubert-Moy, L., Dubreuil, V. (2005). Monitoring land use and land cover changes in oceanic and fragmented landscapes with reconstructed MODIS time series. In: Third International Workshop on the Analysis of Multi-temporal Remote Sensing Images, Multitemp, Biloxi, Mississippi USA, pp. 195–199.
- Lecerf, R., Hubert-Moy, L., Baret, F., Abdel-Latif, B., Corpetti, T., & Nicolas, H. (2008). Estimating biophysical variables at 250m with reconstructed EOS/MODIS time series to monitor fragment landscapes. In: IEEE Int. Geoscience and Remote Sensing Symp., IGARSS'08, Boston, USA, vol 2, pp. 954–957.

- Lefebvre, A., Corpetti, T., & Hubert-Moy, L. (2011). Ondelettes et thorie des vidences pour la classification oriente-objet. caractrisation et suivi des changements d'occupation des sols de la mtropole de rennes. *Revue Internationale de Gomatique*, 21(3), 297–325. doi:10.3166/rig.21.297-325. URL <http://rig.revuesonline.com/article.jsp?articleId=16563>.
- Lillesand, T., & Kiefer, R. (2000). *Remote sensing and image interpretation*, vol, edn. New York, USA.
- Lobell, D. B., & Field, C. B. (2007). Global scale climatecrop yield relationships and the impacts of recent warming. *Environmental Research Letters*, 2(1), 014,002.
- MacQueen, J. B. (1967). Some methods for classification and analysis of multivariate observations. In: Proceedings of 5th Berkeley Symposium on Mathematical Statistics and Probability, Berkeley, University of California Press, 1, vol 6, pp. 281–297.
- Montandon, L. M., & Small, E. E. (2008). The impact of soil reflectance on the quantification of the green vegetation fraction from NDVI. *Remote Sensing of Environment*, 112(4), 1835–1845. doi:10.1016/j.rse.2007.09.007. URL <http://www.sciencedirect.com/science/article/pii/S0034425707004245>.
- Moreau, P., Ruiz, L., Mabon, F., Raimbault, T., Durand, P., Delaby, L., Devienne, S., & Verts, F. (2012). Reconciling technical, economic and environmental efficiency of farming systems in vulnerable areas. *Agriculture, Ecosystems & Environment*, 147, 89–99.
- Peeters, A. (2009). Importance, evolution, environmental impact and future challenges of grasslands and grassland-based systems in Europe. *Grassland Science*, 55(3), 113–125.
- Poudevigne, I., & Alard, D. (1997). Landscape and agricultural patterns in rural areas: a case study in the Brionne basin, Normandy, France. *Journal of Environmental Management*, 50(4).
- Price, J. (1994). How unique are spectral signatures? *Remote Sensing of Environment*, 49(3), 181–186.
- Price JC (1998) An approach for analysis of reflectance spectra. *Remote Sensing of Environment* 64(3):316–330, DOI 10.1016/S0034-4257(98)00008-X. <http://www.sciencedirect.com.gate3.inist.fr/science/article/B6V6V-3V7SDNY-7/2/7242d4a9268104198d28dedbd8422f21>
- Rondeaux, G., Steven, M., & Baret, F. (1996). Optimization of soil-adjusted vegetation indices. *Remote Sensing of Environment*, 55(2), 95–107.
- Rouse, J., Haas, R., Schell, J., Deering, D., & Harlan, J. (1974) Monitoring the vernal advancement of retrogradation of natural vegetation. NASA/GSFC, Type III, Final report Greenbelt, MD, Etats-Unis, 371 p.
- Soudani, K., François, C., le Maire, G., Le Dantec, V., & Dufrière, E. (2006). Comparative analysis of IKONOS, SPOT, and ETM+ data for leaf area index estimation in temperate coniferous and deciduous forest stands. *Remote Sensing of Environment*, 102(12), 161–175. doi:10.1016/j.rse.2006.02.004. URL <http://www.sciencedirect.com/science/article/pii/S0034425706000733>.
- Verhoef, W. (1984). Light scattering by leaf layers with application to canopy reflectance modeling: the sail model. *Remote Sensing of Environment*, 16(2), 125–141.
- Vermote, E., Tanre, D., Deuze, J., Herman, M., & Morcette, J. J. (1997). Second simulation of the satellite signal in the solar spectrum, 6s: an overview. *IEEE Transactions on Geoscience and Remote Sensing*, 35(3), 675–686.
- Vertès, F., Hatch, D., Velthof, G., Taube, F., Laurent, F., Loiseau, P., & Recous, S. (2007). Short-term and cumulative effects of grassland cultivation on nitrogen and carbon cycling in ley-arable rotations. In: Permanent and temporary grassland: Plant, Environment and Economy, 14th symposium of the European Grassland Federation Ghent, A. de Vliegler and L. Carlier, (eds.), Grassland Science in Europe, pp 227–246.
- Viña, A., Gitelson, A. A., Nguy-Robertson, A. L., & Peng, Y. (2011). Comparison of different vegetation indices for the remote assessment of green leaf area index of crops. *Remote Sensing of Environment*, 115(12), 3468–3478. doi:10.1016/j.rse.2011.08.010.
- Wang, J., Rich, P. M., Price, K. P., & Kettle, W. D. (2005). Relations between NDVI, grassland production, and crop yield in the central Great Plains. *Geocarto International*, 20(3), 5–11.
- Wei, X. (2010). Biomass estimation: a remote sensing approach. *Geography Compass*, 4(11), 16351647.
- Weiss, M., & Baret, F. (2010) CAN-EYE V6.1 User Manual. EMMAH, INRA.
- Weiss, M., Baret, F., Myneni, R. B., Pragnère, A., & Knyazikhin, Y. (2000). Investigation of a model inversion technique to estimate canopy biophysical variables from spectral and directional reflectance data. *Agronomie*, 20(1), 3–22.
- Weiss, M., Baret, F., Smith, G. J., Jonckheere, I., & Coppin, P. (2004). Review of methods for in situ leaf area index (LAI) determination: part II. Estimation of LAI, errors and sampling. *Agricultural and Forest Meteorology*, 121(1–2), 37–53.
- Wright, C. K., & Wimberly, M. C. (2013). Recent land use change in the western corn belt threatens grasslands and wetlands. *Proceedings of the National Academy of Sciences*, 110(10), 4134–4139. doi:10.1073/pnas.1215404110. URL <http://www.pnas.org/content/110/10/4134>.
- Wu J, Wang D, Bauer ME (2007) Assessing broadband vegetation indices and QuickBird data in estimating leaf area index of corn and potato canopies. *Field Crops Research* 102(1):33–42, DOI 10.1016/j.fcr.2007.01.003. <http://www.sciencedirect.com/science/article/pii/S0378429007000160>
- Zhang, C., & Guo, X. (2008). Monitoring northern mixed prairie health using broadband satellite imagery. *International Journal of Remote Sensing*, 29(8), 2257–2271.

# B

## Annexe 2

Article

## Combined Use of Multi-Temporal Optical and Radar Satellite Images for Grassland Monitoring

Pauline Dusseux \*, Thomas Corpetti, Laurence Hubert-Moy and Samuel Corgne

LETG Rennes COSTEL laboratory, UMR 6554 CNRS OSU, University of Rennes 2,

Place du recteur Henri Le Moal, 35 043 Rennes Cedex, France;

E-Mails: thomas.corpetti@univ-rennes2.fr (T.C.); laurence.hubert@univ-rennes2.fr (L.H.-M.);

samuel.corgne@univ-rennes2.fr (S.C.)

\* Author to whom correspondence should be addressed; E-Mail: pauline.dusseux@gmail.com;  
Tel.: + 33-2-99-14-18-47.

Received: 23 April 2014; in revised form: 30 May 2014 / Accepted: 23 June 2014 /

Published: 30 June 2014

---

**Abstract:** The aim of this study was to assess the ability of optical images, SAR (Synthetic Aperture Radar) images and the combination of both types of data to discriminate between grasslands and crops in agricultural areas where cloud cover is very high most of the time, which restricts the use of visible and near-infrared satellite data. We compared the performances of variables extracted from four optical and five SAR satellite images with high/very high spatial resolutions acquired during the growing season. A vegetation index, namely the NDVI (Normalized Difference Vegetation Index), and two biophysical variables, the LAI (Leaf Area Index) and the fCOVER (fraction of Vegetation Cover) were computed using optical time series and polarization (HH, VV, HV, VH). The polarization ratio and polarimetric decomposition (Freeman–Durden and Cloude–Pottier) were calculated using SAR time series. Then, variables derived from optical, SAR and both types of remotely-sensed data were successively classified using the Support Vector Machine (SVM) technique. The results show that the classification accuracy of SAR variables is higher than those using optical data (0.98 compared to 0.81). They also highlight that the combination of optical and SAR time series data is of prime interest to discriminate grasslands from crops, allowing an improved classification accuracy.

**Keywords:** imaging data; land use and land cover monitoring; biophysical parameters; polarimetric parameters; time series

---

## 1. Introduction

Land cover and land use changes, which are often associated with agriculture intensification, may have important impacts on environmental systems by increasing water and air pollution, soil degradation or biodiversity loss [1] and on socio-economic systems for stock and winter fodder [2]. The conversion of grass into cropland results in an increase in nitrate leaching and a decrease in carbon storage in soils [3,4]. Thus, considering the increases in cropland at the expense of grasslands observed in many regions of the Earth during the last half century [5,6], the identification of grassland is a key issue for sustainable agriculture.

Grassland can be identified over large areas using optical remote sensing data through the calculation of parameters related to vegetation cover, such as vegetation density, crop height and biomass [7,8]. Vegetation indices, such as the Normalized Difference Vegetation Index (NDVI), or biophysical variables, such as the Leaf Area Index (LAI) or the fraction of Vegetation Cover (fCOVER), can be used to monitor vegetation growth and assess land cover and land uses [9–11]. However, in some regions, the use of optical images during the vegetation period is limited, because of cloud cover and the revisit frequency of satellites. Therefore, Synthetic Aperture Radar (SAR) data, less sensitive to climatic conditions than optical data, can be considered as an ideal complement to optical data for grassland monitoring. Moreover, many studies have shown that SAR data are well correlated with vegetation parameters, such as crop height, biomass or LAI [9,12–16]. Radar polarimetric information (dual or full polarization) appears useful for land use and land cover discrimination [17–20]. Thus, land cover and land use can be studied using polarimetric decompositions (Cloude–Pottier, Freeman–Durden, *etc.*), polarimetric discriminators (ratio, coefficient of variation, *etc.*) useful to characterize different types of scattering mechanisms (surface roughness, specular response, volume, *etc.*). Based on polarimetric synthesis, they describe the polarimetric response of features in the image and allow land cover classification.

Remote sensing images with high spatial and temporal resolutions are required to precisely identify land cover and land use at the field scale in agricultural areas covering more than a few hectares [21]. However, classifications performed with only one image can show poor results for grassland identification, since they show very different spectral responses according to the management practices applied during the growing season. Grassland and cropland can show similar spectral responses depending on the acquisition date. For example, during the growth period of some winter wheat and grasslands, some misclassification errors can be observed. Thus, multi-temporal data can be very useful for inter- and intra-annual grassland monitoring. In this context, upcoming new sensors with high spatial and temporal resolutions, such as Sentinel-1, Sentinel-2 and Ven $\mu$ s, offer new perspectives for grassland monitoring at the field scale.

The aim of this study was to assess the ability of optical images, SAR images and the combination of both types of data to discriminate between grasslands and crops in agricultural areas where cloud cover is very high most of the time, which restricts the use of visible and near-infrared satellite data. For this purpose, we firstly calculated variables extracted from optical and SAR satellite images with high/very high spatial resolutions acquired during the growing season. Then, we successively applied the Support

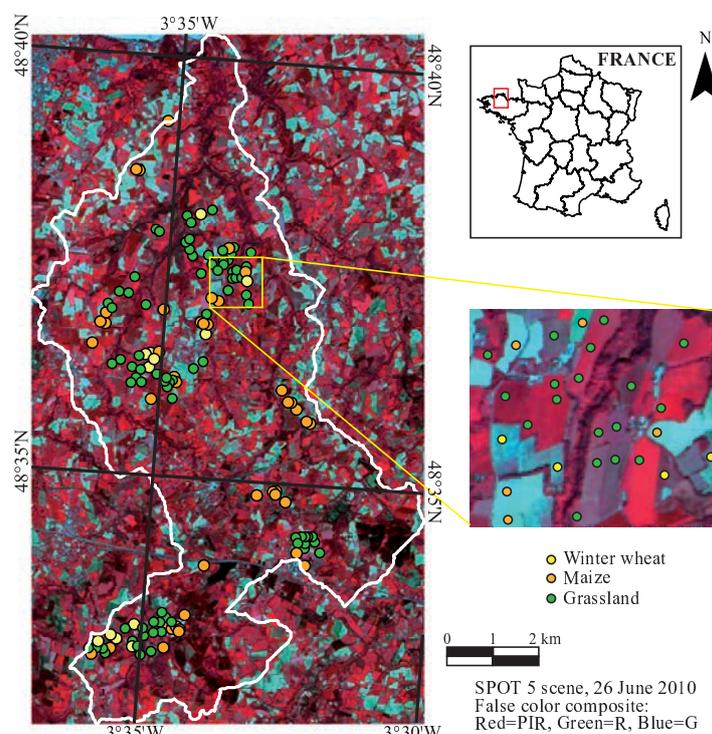
Vector Machine (SVM) classification technique to the variables derived from optical, SAR and both types of remotely sensed data.

## 2. Study Site and Datasets

### 2.1. Site Description

The study was performed on a catchment area of 61.5 km<sup>2</sup> located in central-north Brittany, France (Figure 1). Brittany has a moderate oceanic climate with mild winters and cool summers, high humidity and high mean cloudiness during the year. This study area, the Yar watershed, is characterized by relatively intensive farming, mainly oriented towards cattle production. Besides grassland, the main crops, maize and winter wheat, are produced in relation with industrial breeding. Thus, only these land cover classes, which occupy more than 95% of the arable land, were identified. High nitrogen rates in rivers, largely due to grassland regression and excessive fertilization on crops and grasslands, have been observed for several years on this site. This results in green algae development along the coast. Grasslands cover approximately 60% of the total vegetation area of the watershed and are distributed partly in wetlands (permanent grasslands) and partly in cultivated areas (temporary grasslands). Three types of grassland management practices are encountered in this area, namely grazing, mowing and mixed management (grazing and mowing). Thus, according to these farming practices, grassland fields can show a different vegetation status during the growing period.

**Figure 1.** Location of the study site and field data locations.



## 2.2. Datasets

A series of nine satellite images with high/very high spatial resolution acquired in 2010 during the vegetation period were used for this study. Four cloud-free optical images acquired with SPOT-5 and Landsat sensors were used (Table 1).

**Table 1.** Characteristics of optical satellite images.

<b>Date (DOY) (Days of the Year)</b>	<b>Sensor</b>	<b>Spatial Resolution (m)</b>	<b>Spectral Bands *</b>
April 19, 2010 (109)	SPOT 5	5 × 5	G, R, NIR
May 21, 2010 (141)	SPOT 5	10 × 10	G, R, NIR
June 26, 2010 (177)	SPOT 5	5 × 5	G, R, NIR
September 2, 2010 (245)	Landsat TM5	30 × 30	B, G, R, NIR, SWIR

\* B = blue, G = green, R = red, NIR = near-infrared and SWIR = short-wavelength infrared.

In addition, fully polarimetric RADARSAT-2 images were acquired in ascending orbit and in fine quad-polarization mode (single look complex (SLC) products), thus presenting a nominal swath width of 25 km with a spatial resolution of 12 m (range) × 8 m (azimuth). The FQ18 (Fine Quad-Pol) beam that corresponds to a radar incidence angle of 37.56° was used. Five C-Band images (5405 GHz) were programmed from February 2010, to August 2010, over the study site (Table 2).

**Table 2.** Characteristics of Radarsat-2 images.

<b>Spatial Resolution</b>	12 × 12 m
<b>Azimuth Resolution</b>	8 m
<b>Polarization</b>	Full (HH, VV, HV, VH)
<b>Mode</b>	Fine Quad-Pol
<b>Incidence Angle</b>	37.56° (Right Ascending)
<b>Coverage</b>	25 km × 25 km
<b>Dates (DOY) (Days of the Year)</b>	2 February 2010 (33) 15 June 2010 (166) 9 July 2010 (190) 2 August 2010 (214) 26 August 2010 (238)

All acquired images were used to identify grasslands from crops, since grassland temporal profiles of biophysical or polarimetric variables are very different according to grassland management practices and, thus, can be very similar with crop temporal profiles of biophysical or polarimetric variables. Using multi-temporal optical and/or SAR data rather than one or two images per year should therefore improve grassland identification.

In parallel with image acquisition (with a difference of 1–5 days), field campaigns were conducted monthly during the growing season on the study site to calibrate and validate the classification of satellite images. An inventory of crop type was conducted on 236 fields (10% of the total number of the watershed fields) in 2010 during the time period of image acquisition. In addition to crop type, spectral signatures measured with an ASD FieldSpec-3 spectroradiometer [22,23] and hemispherical photographs [24] were recorded for 20 fields to derive NDVI and LAI values from these two types of data, respectively. Surveys were also conducted with volunteer farmers over four farms to describe the farming practices during the growing season.

### 3. Data Processing

#### 3.1. Optical and SAR Data Preprocessing

In order to reduce errors resulting from instrumental variations in data acquisition, image noise and misregistration, the optical images were corrected from radiometric and atmospheric effects. These corrections were performed applying the 6S model (Second Simulation of a Satellite Signal in the Solar Spectrum vector code) developed by [25]. Then, geometric corrections were undertaken using ArcGIS 10. All data were georeferenced based on the Lambert 2 conformal conic system, the root mean square error being less than one pixel. Finally, the NDVI was calculated [26], and biophysical variables (LAI and fCOVER) were retrieved from satellite images using the PROSAIL (coupling of PROSPECT and SAIL models) radiative transfer model proposed by [27,28].

A  $3 \times 3$  coherency matrix (T3) was firstly extracted from the raw Radarsat-2 images using PCI Geomatics<sup>®</sup> software. A Lee refined filter [29] was applied using a window of  $3 \times 3$  pixels to reduce speckle noise. The images were then geocoded using the Shuttle Radar Topography Mission (SRTM) digital elevation model (DEM) to correct topographic deformations. The images were also geometrically corrected to the Lambert 2 conformal conic system using 40 ground control points selected from orthophoto images with a 0.5-m resolution. The geometric correction accuracy was less than one pixel. All polarizations in  $\sigma^0$  (dB) and intensity ratio (HH/VV, HH/HV and VV/VH) were firstly calculated from the  $3 \times 3$  coherency matrix (T3) before applying two polarimetric decompositions in order to analyze the scattering mechanism of cropped vegetation: (1) the Freeman–Durden decomposition [20] to determine, for each pixel, the power contributions to total power due to double-bounce, volume and surface scattering; (2) the Cloude–Pottier decomposition [30], which is based on the eigenvector-eigenvalues decomposition of the coherence matrix, which computes the entropy ( $H$ , the incoherence degree of the dominant scatterer), the alpha angle,  $\alpha$ , an angle between zero and 90 degrees (the identification of the type of scattering) and the Anisotropy,  $A$  (the amount of mixing between the second and third scattering mechanisms).

In total, fifteen types of variables were extracted from the satellite remote sensing images: three from optical images (NDVI, LAI and fCOVER) and twelve from SAR images ( $\sigma^0$ HH,  $\sigma^0$ VV,  $\sigma^0$ HV, HH/VV, HH/HV, VV/HV, Freeman–Durden decomposition with double-bounce, volume and roughness and Cloude–Pottier decomposition with  $H$ ,  $A$ ,  $\alpha$ ). Since the remote sensing data used in this study have different spatial resolutions, variables derived from optical and SAR images that were calculated at pixel

scale were computed at the field scale by applying the mean variable value within each field to the entire field. Field boundaries were delineated each year by photo-interpretation using the orthophotoplan and the satellite images. For each of these variables, temporal profiles were created: profiles derived from optical images include four points (four dates), while profiles derived from SAR images comprise five points (five dates).

### 3.2. Processing of Optical and SAR Data

#### 3.2.1. Statistical Analysis

Optical and SAR variables have different intervals: for example, LAI ranges between zero and seven, NDVI ranges between zero and one, HH/VV range from 0.5 to 1.3, *etc.* Thus, in order to compare the temporal profiles extracted from the series of optical and SAR images and obtain independent data units, temporal profiles were normalized using the standard score according to the following equation:

$$z = \frac{x - \mu}{\sigma} \quad (1)$$

where  $x$  is the temporal profile,  $\mu$  is the mean and  $\sigma$  the standard deviation of the concerned profiles. Thus, a centered and reduced variable has a mean equal to zero and a standard deviation equal to one.

Then, in order to evaluate and compare the ability of the temporal profiles extracted from optical and polarimetric SAR data to discriminate grasslands from crops, transformed divergence (TD) was used. TD is a tool used to measure the separability between two profiles [31]. Firstly, the divergence ( $D_{ij}$ ) was computed according to Equation (2), and then, the TD ( $D_{ij}^T$ ) was calculated according to Equation (3).

$$D_{ij} = \frac{1}{2}Tr\{(cov_i - cov_j)(cov_j^{-1} - cov_i^{-1})\} + \frac{1}{2}Tr\{(cov_i^{-1} + cov_j^{-1})(\bar{x}_i - \bar{x}_j)(\bar{x}_i - \bar{x}_j)^t\} \quad (2)$$

where  $i$  and  $j$  are the profiles (of two classes) to compare,  $cov_i$  is the covariance matrix of profile  $i$ ,  $\bar{x}_i$  is the mean vector of signature  $i$ ,  $Tr$  is the trace function and  $t$  is the transposition function.

$$D_{ij}^T = 2(1 - \exp(\frac{-D_{ij}}{8})) \quad (3)$$

TD values, which can range from zero to two, decrease with increasing distances between classes. According to the empirical relationship between TD and the probability of correct classification [32]: classes can be separated with TD values greater than 1.9; classes can be fairly well separated with TD values between 1.7 and 1.9; and classes can be poorly separated with TD values below 1.7. TD can be computed for any combination of variables that are used to classify images and, thus, can be applied to a time series of remote sensing data.

#### 3.2.2. Classification

According to TD analysis, the most discriminative optical and SAR variables were then selected and an SVM (support vector machine) procedure was performed to evaluate their ability to discriminate grasslands from crops. Well-known SVM techniques [33,34] are able to efficiently classify a set of data

where the separability between classes is not obvious (the main idea consists in performing a projection of all data onto a specific space where the separability is higher). To evaluate classification performance, 2/3 of the 236 sample fields were used for training and 1/3 for validation. Fifteen percent of the validation set corresponds to winter wheat fields, 22% to maize and 63% to grassland fields. Classification accuracy was assessed using the kappa index (K) and the overall accuracy [35].

## 4. Results and Discussion

### 4.1. Analysis of Class Separability

The transformed divergence values between the three land cover classes (winter wheat, maize and grassland) calculated from the temporal profiles of variables derived from optical and SAR images are given in Table 3. The variable sets included three optical variables and in terms of SAR variables: three single polarizations, one combination of polarizations, three polarization ratios and two polarimetric decomposition parameters. It can be observed that TD values are very high ( $TD \geq 1.9$ ), indicating that the land cover classes have very good separability for any of the optical and SAR variables. The use of time series of remotely sensed data allows plant growth to be monitored and winter wheat and maize to be discriminated from grasslands.

**Table 3.** Transformed divergence values between the land cover classes for optical and SAR variables.

Variable Set	Land Cover	Winter Wheat-Maize	Winter Wheat-Grassland	Maize-Grassland
<b>Optical VARIABLES</b>				
NDVI		2.00	1.87	1.99
LAI		2.00	1.99	2.00
fCOVER		2.00	1.97	2.00
<b>SAR VARIABLES</b>				
<b>Single polarization</b>				
$\sigma^0_{HH}$		1.91	1.99	2.00
$\sigma^0_{VV}$		1.95	2.00	1.98
$\sigma^0_{HV}$		1.98	1.92	1.86
<b>Combination of polarizations</b>				
HH, VV, HV		2.00	2.00	2.00
<b>Polarization ratio</b>				
HH/VV		2.00	2.00	1.90
HH/HV		1.92	2.00	1.99
VV/HV		2.00	2.00	1.70
<b>Polarimetric decomposition</b>				
Freeman–Durden		2.00	2.00	2.00
Cloude–Pottier		2.00	2.00	2.00

Regarding the TD values obtained with temporal profiles of variables derived from optical images, the biophysical variables are the most accurate for the discrimination of the three land cover classes. It is related to the fact that NDVI is sensitive to the soil contribution and to the atmosphere [36,37]. Moreover, some NDVI differences are caused by sensor-specific relative spectral response functions [38]. In addition, it was shown that for a vegetation cover rate above 60%, vegetation indices using the NIR spectral band are insensitive to changes related to vegetation [39,40]. On the other hand, biophysical parameters have been proven to be very efficient and suitable for vegetation monitoring [7,10,41,42]. The TD values of LAI are the highest, showing that the temporal evolution of LAI is indeed informative about vegetation growth, density and land management practices [43,44]. The TD values for fCOVER are slightly lower. Moreover, TD values between winter wheat and grassland are a bit lower for NDVI temporal profiles than for LAI temporal profiles. Thus, we suggest relying on LAI series to discriminate grasslands from the two other land cover classes.

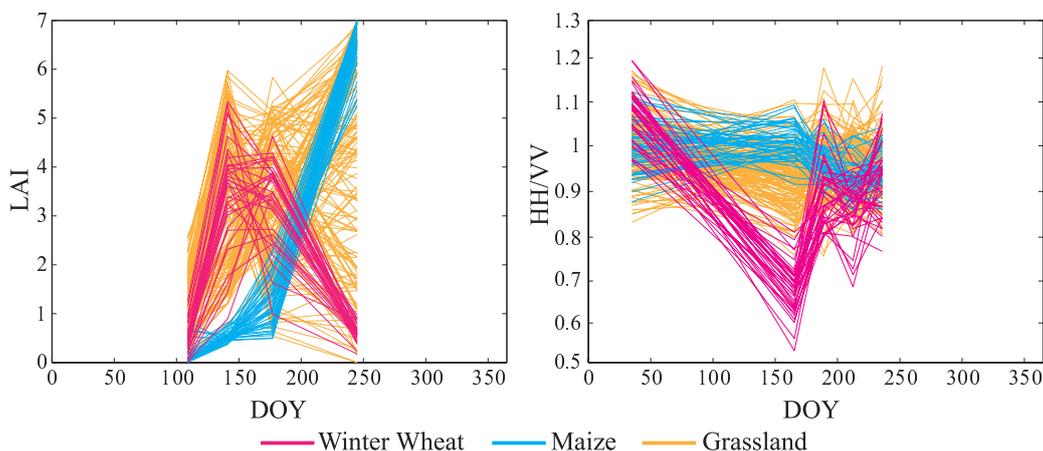
Concerning SAR variables, the combination of polarizations (HH, VV, HV, VH) and the two polarimetric decompositions (Freeman–Durden and Cloude–Pottier) show a TD value of 2.0, which is consistent with numerous studies showing the interest of radar polarimetric information for land cover monitoring [18–20]. Moreover, polarimetric information is well correlated with vegetation status [12–14,16]. Thus, the classification process was performed using these three variable sets.

## 4.2. Analysis of Temporal Variables Used for Classification

### 4.2.1. LAI and HH/VV Variables Extracted from Optical and SAR Data, Respectively

Field temporal profiles of LAI and the HH/VV polarization ratio are illustrated in Figure 2 for the three land cover classes. LAI provides information on vegetation growth and status, and the HH/VV polarization ratio indirectly provides information on agricultural practices [17]. Indeed, in C-band,  $\sigma^0$  HH is generally higher than that of  $\sigma^0$  VV, because of the stronger attenuation of VV backscattering by vertical stems [13,45,46]. Backscattering coefficients are thus strongly linked to the phenology of the crop, which influences the scattering mechanisms of the target [12–14]. Thus, numerous studies use a multitemporal HH/VV ratio for land use and land cover monitoring in agricultural areas [17,47,48].

**Figure 2.** Field temporal profiles of the LAI variable and HH/VV polarization ratio.



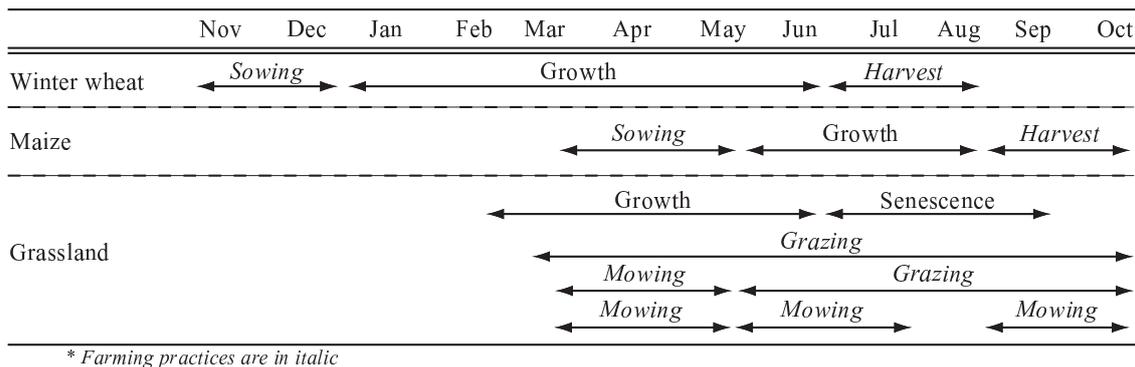
Land cover classes show very different profiles based on the agricultural calendar (Figure 3) reflecting farming practices:

- The LAI profiles for the winter wheat illustrate the growth period from leaf development to flowering (May (DOY: 141) and June (DOY: 177) images) with LAI values higher than three followed by harvest after senescence at the end of the summer period (DOY: 245) with values lower than one. HH/VV ratios show values close to one at the beginning of leaf development (February (DOY: 33)), which highlights few backscattering variations between HH and VV due to the low development of winter wheat during this period (specular scattering). On the other hand, at the flowering stage during the spring period (June (DOY: 166)), values are comprised between 0.5 and 0.8, illustrating high levels of surface roughness explained by the growth of plants (low values of backscattering coefficient VV due to vegetation growth). At the senescence stage (July (DOY: 190)), the harvest begins and the ratio values increase. In early August (DOY: 214), the decrease of HH/VV ratio values can be explained by vegetation regrowth, while at the end of August (DOY: 238), the increase of HH/VV ratio values is related to the plowing of winter wheat.
- LAI profiles of maize illustrate bare soil and a sowing period lasting until the end of June (DOY: 177) followed by the growth period from leaf development to ripening until September (DOY: 245). The HH/VV ratio values appear very heterogeneous during the winter period in February (DOY: 33). At this time period, maize has not yet been sown (sowing in April), and before this crop, different land use and land cover practices (labor, intercrop, *etc.*) can be observed associated with very different scattering mechanisms. In June (DOY: 166), the HH/VV ratio values are high (between 0.9 and 1.1), showing different dominant scattering mechanisms for each polarization corresponding to leaf development (maize growth). During stem elongation and flowering in July (DOY: 190) and August (DOY: 214 and 238), maize HH/VV ratio values are lower (between 0.8 and one), because of the presence of a high level of vegetation cover during this period (diffuse scattering).
- LAI profiles of grasslands show several shapes according to farming practices. We can observe high LAI values during the growth period (from leaf development to flowering), from April to June, whereas after this time period, LAI values decrease at varying rates according to grassland management practices. Indeed, three farming practices can be identified within the grassland class: grazing, mowing and mixed management. A strong decrease in LAI values can be observed after inflorescence emergence in June (DOY: 177) for mown fields, while LAI values decrease more slowly for grazed fields. After the end of the summer period, in September (DOY: 245), two different LAI scenarios are observed for mowed fields according to the ripening stage: some of them were recently mowed; thus, the LAI values are very low (less than one); and some of them were not yet mowed and showed very high LAI values (more than five). Grazing occurred during the growing season after stem elongation. The HH/VV ratio profiles of grassland management were characterized by high variance for each date, and grazing, mowing and mixed management in grasslands could not be exactly discriminated.

Temporal profiles allow land cover classes to be discriminated, while values of the considered variables are similar on some dates. The growth status of different crops can be similar on some time

periods. Furthermore, some dissimilarities can be observed between values of the three land cover classes during the month of June (DOY 166 for LAI and 177 for HH/VV ratio); thus, it appears to be the best time period when optical and SAR data are combined. LAI values of maize are much smaller than those of grassland and winter wheat, while the HH/VV ratio values of winter wheat class are smaller than those of maize and grassland (Figure 2). Therefore, the three land cover classes can be discriminated using the combination of LAI and HH/VV ratio values.

**Figure 3.** Phenology stages and farming practices for the three land cover classes.



**Figure 4.** Scatter plot of the field samples of the three land cover classes in a space comprising the HH/VV polarization ratio and the LAI variable for June 2010 (satellite images: DOY 166 for the HH/VV ratio and DOY 177 for the LAI variable).

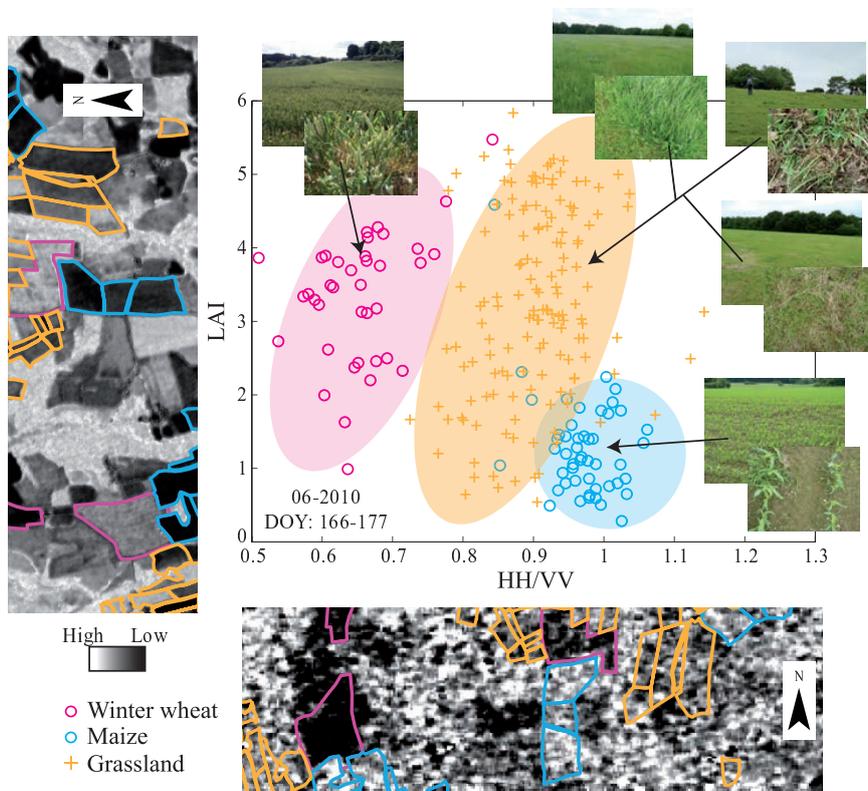


Figure 4 is the scatter plot of the field samples of the three land cover classes considered in a space comprising the HH/VV polarization ratio and the LAI variable for June, 2010, the only month during this

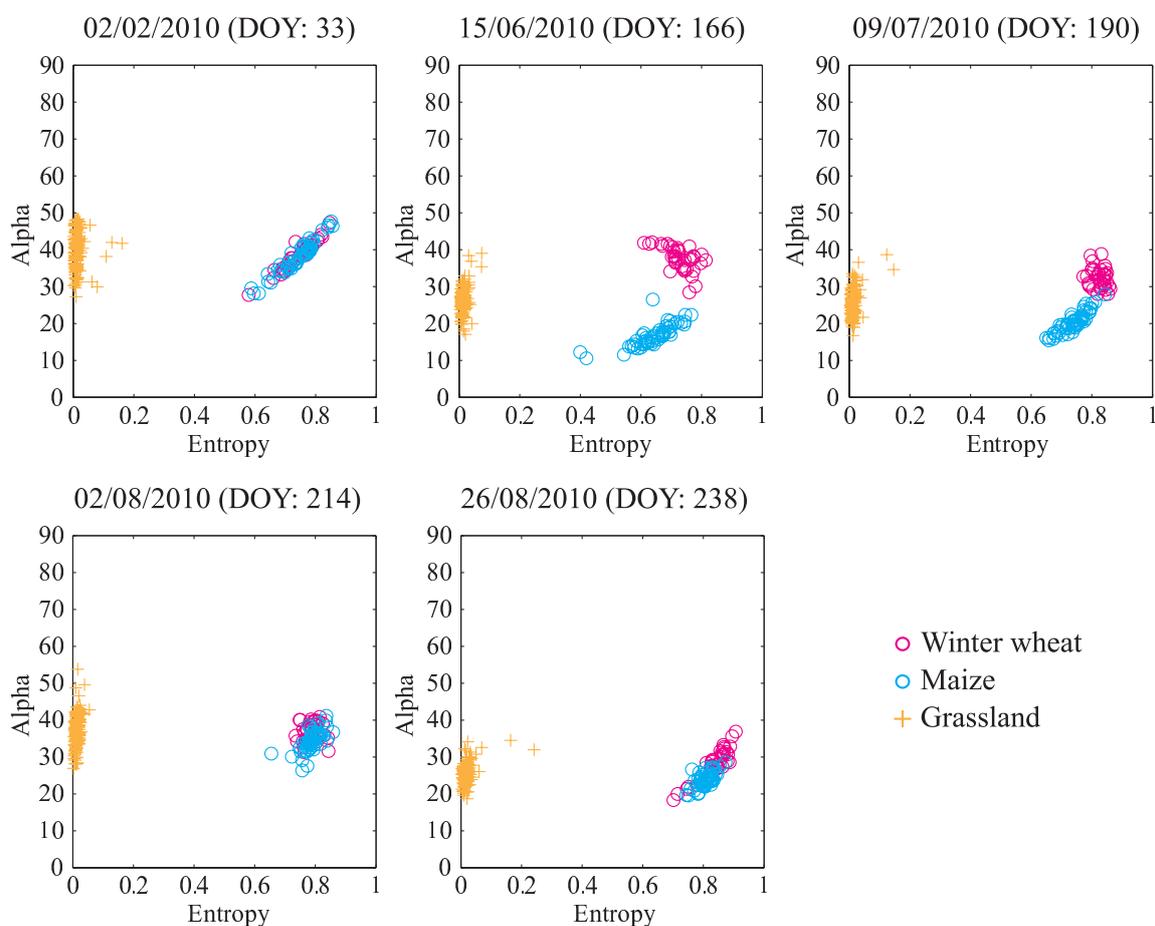
study in which optical and SAR data were acquired. The three land cover classes were well discriminated by the HH/VV and LAI combination. In June, values for winter wheat class were quite unique in that the HH/VV polarization ratio values were much smaller than those for the other classes ( $<0.8$ , attenuation of the backscattering coefficient in VV polarization), while LAI values were similar to those of the grassland class. The maize HH/VV polarization ratio values were generally much higher than those from the other classes ( $>0.9$ , a similar backscattering coefficient for the two polarizations due to bare soil contribution), but a limited number of grassland fields showed the same HH/VV values. Thus, by the combination of the June HH/VV ratio and LAI values, maize identification was achieved with small LAI values ( $<2$ ) and high HH/VV values ( $>0.9$ ). Grassland can be discriminated from winter wheat with HH/VV ratio values comprised between 0.8 and 0.9 (winter wheat HH/VV ratio values are comprised between 0.5 and 0.8). Grassland can be discriminated from maize with (1) LAI values comprised between zero and two and HH/VV ratio values comprised between 0.8 and 0.9 or with (2) LAI values higher than two (maize LAI values are smaller than two and HH/VV ratio values are higher than 0.9).

#### 4.2.2. Entropy and Alpha Polarimetric Variables Extracted from SAR Data

Illustrated in Figure 5, winter wheat, maize and grassland field samples were then plotted for each acquisition date in the data space of the entropy and alpha polarimetric variables, which represent scattering mechanisms defined by [30]. The Cloude–Pottier representation ( $H, \alpha$ ) helps to define the dominant type of scattering: multiple, volume or surface. Alpha angle ( $\alpha$ ) values are comprised between  $0^\circ$  and  $90^\circ$ , with  $0^\circ$  indicating dominant smooth scattering,  $45^\circ$  a dominant volume or dipolar scattering and  $90^\circ$  diffuse scattering (or dihedral). When the entropy variable ( $H$ ) is equal to zero, only one scattering dominant mechanism occurs compared to several scattering mechanisms if  $H = 1$ . Figure 5 shows a very good separability between the three land cover classes, particularly in June. This figure also highlights that it is necessary to use multi-temporal data to identify these classes, since depending on the acquisition date, winter wheat and maize show similarities (DOY: 33, 214 and 238) and, thus, cannot be discriminated using only these dates (as seen previously with temporal profiles (Figure 4) and the agricultural calendar (Figure 3)). The temporal variation of radar response has proven to be effective for land cover monitoring, varying according to vegetation growth to the saturation level. Indeed, as shown by [13] or [49], saturation can be observed with radar backscattering on sugar cane or rice with a crop height higher than 50 cm. We can observe this phenomenon on maize and winter wheat fields from August when maize and winter wheat show similar values (Figure 5). Thus, the use of multi-temporal data is interesting for crop monitoring. Generally, grasslands show lower entropy values (comprised between zero and 0.2) than winter wheat and maize classes ( $H$  values comprised between 0.6 and 0.9) that are characterized by different scattering mechanisms (surface, double-bounce, *etc.*). Moreover, June and July appear to be the most appropriate time period to distinguish winter wheat from maize. We observed that winter wheat have higher  $\alpha$  values than maize, from 30 to 45 and from 10 to 25, respectively, which indicates a dominant volume scattering for winter wheat and a smoother surface scattering contribution for maize in June. According to the diagram of the bi-dimensional classification based on the entropy ( $H$ ) and orientation alpha angle ( $\alpha$ ) from [30,50], during these two months, the dominant scattering mechanisms for winter wheat is the volume with a medium entropy and the dominant

scattering mechanisms for maize is the surface with a medium entropy [51,52]. Maize fields are just being sown at this period; thus, bare soil is dominant while winter wheat fields are already growing. Concerning grasslands, the dominant scattering mechanism is the surface with a very low entropy. Moreover, according to [30], low values of entropy ( $H < 0.5$ ) are of less interest and provide fewer details on the class. Thus, it appears that SAR can be very useful in classifying the three considered land cover classes of interest.

**Figure 5.** Scatter plot of the three land cover classes in the space of the entropy ( $H$ ) and alpha ( $\alpha$ ) variables derived from Cloude–Pottier decomposition for each SAR acquisition date.



### 4.3. Classification

Tables 4–7 show the confusion matrices of the land cover classifications using optical or SAR variables. Globally, land cover classes are well separated: classifications using Freeman–Durden decomposition parameters (Table 6) or Cloude–Pottier decomposition parameters (Table 7) produced the highest overall accuracy (OA) and kappa values (K) with 97% OA,  $K = 0.95$  and 99% OA,  $K = 0.98$ , respectively. Classifications using the LAI variable (Table 4) show an overall accuracy of 88% and a kappa value of 0.81. Misclassification errors can be observed between winter wheat and grassland classes, as previously detailed and illustrated in Figure 6, these two classes showing similar LAI temporal profiles during the vegetation development stage (Figures 2 and 3). Moreover,

only four optical images were used in this study, because of cloud cover during the summer period; thus, some information about vegetation status is missing. Concerning classifications using SAR variables, the combination of polarizations (Table 5) show an overall accuracy of 96% and a kappa value of 0.87. We observe an underestimation of 17% of winter wheat in favor of the grassland class and an underestimation of 2% of grassland in favor of the maize. The classification results using Freeman–Durden decomposition parameters (Table 6) and Cloude–Pottier decomposition parameters (Table 7) show some misclassification between winter wheat and maize, while grassland fields are very well separated.

Tables 8–10 shows the confusion matrices of land cover classifications using the combination of optical and SAR data. Land cover classes are very well separated (100% accuracy) with the combination of LAI Freeman–Durden decomposition parameters and LAI Cloude–Pottier decomposition parameters. The combination of optical and SAR data eliminated misclassification errors. Thus, four optical images and five SAR images distributed throughout the year are enough to discriminate winter wheat, maize and grassland. Moreover, the use of polarimetric decomposition, such as Freeman–Durden or Cloude–Pottier, in addition to LAI, remove possible misclassification errors between land cover classes, as shown by [12]. Furthermore, polarimetric data, such as Radarsat-2, can be very useful to discriminate crops in addition to optical data [51].

**Table 4.** Confusion matrix (in %) for land cover classification using the LAI variable derived from four optical images.

	Winter Wheat	Maize	Grassland	Total
Winter wheat	83	0	14	22
Maize	0	100	0	22
Grassland	17	0	86	56
Total	100	100	100	100

Overall accuracy = 88%, kappa index = 0.81.

**Table 5.** Confusion matrix (in %) for land cover classification using a combination of polarizations, HH, VV and HV computed from five SAR images.

	Winter Wheat	Maize	Grassland	Total
Winter wheat	83	0	0	13
Maize	0	100	2	23
Grassland	17	0	98	64
Total	100	100	100	100

Overall accuracy = 96%, kappa index = 0.87.

**Table 6.** Confusion matrix (in %) for land cover classification using the Freeman–Durden decomposition parameters computed from five SAR images.

	Winter Wheat	Maize	Grassland	Total
Winter wheat	83	0	0	13
Maize	17	100	0	24
Grassland	0	0	100	63
Total	100	100	100	100

Overall accuracy = 97%, kappa index = 0.95.

**Table 7.** Confusion matrix (in %) for land cover classification using the Cloude–Pottier decomposition parameters computed from five SAR images.

	Winter Wheat	Maize	Grassland	Total
Winter wheat	92	0	0	14
Maize	8	100	0	23
Grassland	0	0	100	63
Total	100	100	100	100

Overall accuracy = 99%, kappa index = 0.98.

**Table 8.** Confusion matrix (in %) for land cover classification using a combination of optical and SAR variables: LAI and HH, VV, HV.

	Winter Wheat	Maize	Grassland	Total
Winter wheat	92	0	2	15
Maize	0	100	0	22
Grassland	8	0	98	63
Total	100	100	100	100

Overall accuracy = 97%, kappa index = 0.94.

**Table 9.** Confusion matrix (in %) for land cover classification using a combination of optical and SAR variables: LAI and Freeman–Durden decomposition parameters.

	Winter Wheat	Maize	Grassland	Total
Winter wheat	100	0	0	15
Maize	0	100	0	22
Grassland	0	0	100	63
Total	100	100	100	100

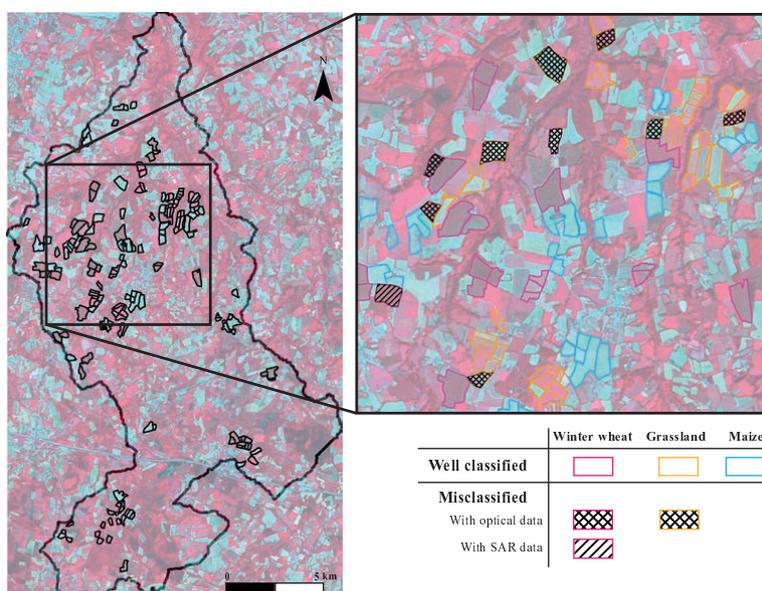
Overall accuracy = 100%, kappa index = 1.

**Table 10.** Confusion matrix (in %) for land cover classification using a combination of optical and SAR variables: LAI and Cloude–Pottier decomposition parameters.

	Winter Wheat	Maize	Grassland	Total
Winter wheat	100	0	0	15
Maize	0	100	0	22
Grassland	0	0	100	63
Total	100	100	100	100

Overall accuracy = 100%, kappa index = 1.

**Figure 6.** Illustration of classification results: extract of the study site of misclassified fields using the LAI variable or Cloude–Pottier decomposition parameters and well classified fields using a combination of LAI and Cloude–Pottier decomposition parameters.



## 5. Conclusions

In this study, we have evaluated the ability of optical and/or SAR time series images to discriminate between grasslands and crops in agricultural areas where cloud cover is very high most of the time. We showed that among a series of variables derived from multi-temporal images acquired with optical and SAR sensors, LAI and Freeman–Durden and Cloude–Pottier polarimetric decompositions were proven to be the best optical and SAR variables, respectively, to identify grasslands. We also highlight that (i) the classification accuracy of SAR variables alone is higher than that of optical variables alone (K: 0.98 compared to 0.81); (ii) classification using Cloude–Pottier decomposition parameters shows a higher accuracy than that using the combination of polarizations HH, VV and HV and the Freeman–Durden decomposition parameters (K: 0.98 compared to 0.87 and 0.95, respectively); and (iii) the combination of the LAI variable and SAR decomposition parameters (Freeman–Durden and Cloude–Pottier) allow grassland to be discriminated from cropland with an accuracy of 100%. As a perspective, this approach could be applied to multi-annual SAR and optical time series to identify grassland removal and, thus, to monitor grassland inter-annual dynamics and to define their status in

farming systems. Furthermore, in the context of upcoming sensors Sentinel-1, Sentinel-2 or Venus, a large amount of satellite images with high spatial and temporal resolutions will be soon available, offering new perspectives for intra-annual grassland monitoring. Some grassland farming practices, such as grazing, mowing and fertilizing, as well as their intensity, could be investigated using the synergy of remotely sensed optical and SAR time series. This method, based on the use of temporal profiles derived from optical and SAR data, can be extended to other regions to monitor areas with similar characteristics and same land cover classes, as well as to identify other land cover types. The main requirement is that time series of satellite images should be acquired during the vegetation growing period. Moreover, in parallel with image acquisition, field campaigns should be conducted to assess image classification accuracy.

### Acknowledgments

This work was supported by the National Agency for Research (ANR) SYSTERRA-ACASSYA (Supporting the agro ecological evolution of breeding systems in coastal watersheds) program (ANR-08-STRA-01). We would also like to thank the National Centre for Space Studies (CNES) for providing us with the optical satellite images, Vigisat-CLS (Collecte Localisation Satellites)S for providing us with the SAR data, Sally Ferguson for revising the manuscript and the anonymous referees for their valuable comments.

### Author Contributions

All authors contributed extensively to the work presented in this paper. Pauline Dusseux and Samuel Corgne processed the optical and radar images and conducted the field work. All authors led an interpretation of the results and drafted the manuscript. Laurence Hubert-Moy and Thomas Corpetti initiated the project, which was revised by all authors. All authors read and approved the final manuscript.

### Conflicts of Interest

The authors declare no conflicts of interest.

### References

1. Lobell, D.B.; Field, C.B. Global scale climate-crop yield relationships and the impacts of recent warming. *Environ. Res. Lett.* **2007**, *2*, 014002, doi:10.1088/1748-9326/2/1/014002.
2. Batáry, P.; Báldi, A.; Erdős, S. Grassland *versus* non-grassland bird abundance and diversity in managed grasslands: Local, landscape and regional scale effects. *Biodivers. Conserv.* **2007**, *16*, 871–881.

3. Vertès, F.; Hatch, D.; Velthof, G.; Taube, F.; Laurent, F.; Loiseau, P.; Recous, S. Short-Term and Cumulative Effects of Grassland Cultivation on Nitrogen and Carbon Cycling in Ley-Arable Rotations. In Proceedings of 14th Symposium of the Grassland Science in Europe, Permanent and Temporary Grassland: Plant, Environment and Economy, Gent, Belgium, 3–5 September 2007; pp. 227–246.
4. Arrouays, D.; Deslais, W.; Badeau, V. The carbon content of topsoil and its geographical distribution in France. *Soil Use Manag.* **2001**, *17*, 7–11.
5. Peeters, A. Importance, evolution, environmental impact and future challenges of grasslands and grassland-based systems in Europe. *Grassl. Sci.* **2009**, *55*, 113–125.
6. Poudevigne, I.; Alard, D. Landscape and agricultural patterns in rural areas: A case study in the Brionne Basin, Normandy, France. *J. Environ. Manag.* **1997**, *50*, 335–349.
7. Jacquemoud, S.; Verhoef, W.; Baret, F.; Bacour, C.; Zarco-Tejada, P.; Asner, G.; François, C.; Ustin, S. PROSPECT + SAIL models: A review of use for vegetation characterization. *Remote Sens. Environ.* **2009**, *113*, S56–S66.
8. Rondeaux, G.; Steven, M.; Baret, F. Optimization of soil-adjusted vegetation indices. *Remote Sens. Environ.* **1996**, *55*, 95–107.
9. Gao, S.; Niu, Z.; Huang, N.; Hou, X. Estimating the Leaf Area Index, height and biomass of maize using HJ-1 and RADARSAT-2. *Int. J. Appl. Earth Obs. Geoinf.* **2013**, *24*, 1–8.
10. Friedl, M.; Schimel, D.; Michaelsen, J.; Davis, F.W.; Walker, H. Estimating grassland biomass and Leaf Area Index using ground and satellite data. *Int. J. Remote Sens.* **1994**, *15*, 1401–1420.
11. Wei, X. Biomass estimation: A remote sensing approach. *Geogr. Compass* **2010**, *4*, 1635–1647.
12. McNairn, H.; Brisco, B. The application of C-band polarimetric SAR for agriculture: A review. *Can. J. Remote Sens.* **2004**, *30*, 525–542.
13. Baghdadi, N.; Boyer, N.; Todoroff, P.; El Hajj, M.; Bégué, A. Potential of SAR sensors TerraSAR-X, ASAR/ENVISAT and PALSAR/ALOS for monitoring sugarcane crops on Reunion Island. *Remote Sens. Environ.* **2009**, *113*, 1724–1738.
14. Inoue, Y.; Sakaiya, E.; Wang, C. Capability of C-band backscattering coefficients from high-resolution satellite SAR sensors to assess biophysical variables in paddy rice. *Remote Sens. Environ.* **2014**, *140*, 257–266.
15. Bouman, B.A.M. Crop parameter estimation from ground-based x-band (3-cm wave) radar backscattering data. *Remote Sens. Environ.* **1991**, *37*, 193–205.
16. Le Toan, T.; Beaudoin, A.; Riom, J.; Guyon, D. Relating forest biomass to SAR data. *IEEE Trans. Geosci. Remote Sens.* **1992**, *30*, 403–411.
17. Liu, C.; Shang, J.; Vachon, P.; McNairn, H. Multiyear crop monitoring using polarimetric RADARSAT-2 data. *IEEE Trans. Geosci. Remote Sens.* **2013**, *51*, 2227–2240.
18. Buckley, J.; Smith, A. Monitoring Grasslands with Radarsat 2 Quad-Pol Imagery. In Proceedings of IEEE International Geoscience and Remote Sensing Symposium, IGARSS '10, Honolulu, HI, USA, 25–30 July 2010; pp. 3090–3093.
19. Smith, A.M.; Buckley, J.R. Investigating RADARSAT-2 as a tool for monitoring grassland in western Canada. *Can. J. Remote Sens.* **2011**, *37*, 93–102.

20. Freeman, A.; Villasenor, J.; Klein, J.; Hoogeboom, P.; Groot, J. On the use of multi-frequency and polarimetric radar backscatter features for classification of agricultural crops. *Int. J. Remote Sens.* **1994**, *15*, 1799–1812.
21. Dusseux, P.; Hubert-Moy, L.; Lecerf, R.; Gong, X.; Corpetti, T. Identification of Grazed and Mown Grasslands Using a Time Series of High-Spatial-Resolution Remote Sensing Images. In Proceedings of 6th International Workshop on the Analysis of Multi-temporal Remote Sensing Images (Multi-Temp), Trento, Italy, 12–14 July 2011; pp. 145–148.
22. ASD. *FieldSpec 3 Portable Spectroradiometer User's Guide*; Analytical Spectral Devices: Boulder, CO, USA, 2000.
23. Lillesand, T.; Kiefer, R.; Chipman, J. *Remote Sensing and Image Interpretation*, 6th ed.; John Wiley and Sons: Toronto, ON, Canada, 2008; p. 768.
24. Weiss, M.; Baret, F.; Smith, G.J.; Jonckheere, I.; Coppin, P. Review of methods for *in situ* Leaf Area Index (LAI) determination: Part II. Estimation of LAI, errors and sampling. *Agric. For. Meteorol.* **2004**, *121*, 37–53.
25. Vermote, E.; Tanre, D.; Deuze, J.; Herman, M.; Morcette, J.J. Second simulation of the satellite signal in the solar spectrum, 6S: An overview. *IEEE Trans. Geosci. Remote Sens.* **1997**, *35*, 675–686.
26. Rouse, J.; Haas, R.; Schell, J.; Deering, D.; Harlan, J. *Monitoring the Vernal Advancement of Retrogradation of Natural Vegetation*; Type III, Final report; NASA/GSFC: Greenbelt, MD, USA, 1974; p. 371.
27. Jacquemoud, S.; Baret, F. PROSPECT: A model of leaf optical properties spectra. *Remote Sens. Environ.* **1990**, *34*, 75–91.
28. Verhoef, W. Light scattering by leaf layers with application to canopy reflectance modeling: The SAIL model. *Remote Sens. Environ.* **1984**, *16*, 125–141.
29. Lee, J.; Grunes, M.; de Grandi, G. Polarimetric SAR speckle filtering and its implication for classification. *IEEE Trans. Geosci. Remote Sens.* **1999**, *37*, 2363–2373.
30. Cloude, S.; Pottier, E. An entropy based classification scheme for land applications of polarimetric SAR. *IEEE Trans. Geosci. Remote Sens.* **1997**, *35*, 68–78.
31. Richards, J.A. *Remote Sensing Digital Image Analysis: An Introduction*, 5th ed.; Springer: New Jersey, NJ, USA, 2012; p. 494.
32. Swain, P.H.; King, R.C. Two Effective Feature Selection Criteria for Multispectral Remote Sensing. In Proceedings of the First International Joint Conferences on Pattern Recognition, Washington, DC, USA, 1973; pp. 536–540.
33. Zhang, T. An introduction to support vector machines and other Kernel-based learning methods. *AI Mag.* **2001**, *22*, 103–104.
34. Burges, C.J.C. A tutorial on support vector machines for pattern recognition. *Data Min. Knowl. Discov.* **1998**, *2*, 121–167.
35. Congalton, R.G. A review of assessing the accuracy of classifications of remotely sensed data. *Remote Sens. Environ.* **1991**, *37*, 35–46.
36. Henebry, G.M. Detecting change in grasslands using measures of spatial dependence with Landsat TM data. *Remote Sens. Environ.* **1993**, *46*, 223–234.

37. Baret, F.; Guyot, G. Potentials and limits of vegetation indices for LAI and APAR assessment. *Remote Sens. Environ.* **1991**, *35*, 161–173.
38. Franke, J.; Heinzl, V.; Menz, G. Assessment of NDVI- Differences Caused by Sensor Specific Relative Spectral Response Functions. In Proceedings of IEEE International Geoscience and Remote Sensing Symposium, Denver, CO, USA, 31 July–4 August 2006; pp. 1138–1141.
39. Gitelson, A.A.; Kaufman, Y.J.; Stark, R.; Rundquist, D. Novel algorithms for remote estimation of vegetation fraction. *Remote Sens. Environ.* **2002**, *80*, 76–87.
40. Glenn, E.P.; Huete, A.R.; Nagler, P.L.; Nelson, S.G. Relationship between remotely-sensed vegetation indices, canopy attributes and plant physiological processes: What vegetation indices can and cannot tell us about the landscape. *Sensors* **2008**, *8*, 2136–2160.
41. Zhang, C.; Guo, X. Monitoring northern mixed prairie health using broadband satellite imagery. *Int. J. Remote Sens.* **2008**, *29*, 2257–2271.
42. Guo, X.; Price, K.P.; Stiles, J.M. Biophysical and spectral characteristics of cool- and warm-season grasslands under three land management practices in Eastern Kansas. *Nat. Resour. Res.* **2000**, *9*, 321–331.
43. Asam, S.; Fabritius, H.; Klein, D.; Conrad, C.; Dech, S. Derivation of Leaf Area Index for grassland within alpine upland using multi-temporal RapidEye data. *Int. J. Remote Sens.* **2013**, *34*, 8628–8652.
44. Chen, J.M.; Black, T.A. Measuring Leaf Area Index of plant canopies with branch architecture. *Agric. For. Meteorol.* **1991**, *57*, 1–12.
45. Ribbes, F. Rice field mapping and monitoring with RADARSAT data. *Int. J. Remote Sens.* **1999**, *20*, 745–765.
46. Le Toan, T.; Ribbes, F.; Wang, L.; Floury, N.; Ding, K.; Kong, J.; Fujita, M.; Kurosu, T. Rice crop mapping and monitoring using ERS-1 data based on experiment and modeling results. *IEEE Trans. Geosci. Remote Sens.* **1997**, *35*, 41–56.
47. Betbeder, J.; Rapinel, S.; Corpetti, T.; Pottier, E.; Corgne, S.; Hubert-Moy, L. Multi-temporal classification of TerraSAR-X data for wetland vegetation mapping. *Proc. SPIE* **2013**, 8887, doi:10.1117/12.2029092.
48. Koppe, W.; Gnyp, M.L.; Hütt, C.; Yao, Y.; Miao, Y.; Chen, X.; Bareth, G. Rice monitoring with multi-temporal and dual-polarimetric TerraSAR-X data. *Int. J. Appl. Earth Obs. Geoinf.* **2013**, *21*, 568–576.
49. Lam-Dao, N.; Le Toan, T.; Apan, A.; Bouvet, A.; Young, F.; Le-Van, T. Effects of changing rice cultural practices on C-band synthetic aperture radar backscatter using Envisat advanced synthetic aperture radar data in the Mekong River Delta. *J. Appl. Remote Sens.* **2009**, *3*, 033563:1–033563:17.
50. Lee, J.; Pottier, E. *Polarimetric Radar Imaging: From Basics to Applications*; CRC Press: New York, NY, USA, 2009; p. 422.
51. McNairn, H.; Shang, J.; Jiao, X.; Champagne, C. The contribution of ALOS PALSAR multipolarization and polarimetric data to crop classification. *IEEE Trans. Geosci. Remote Sens.* **2009**, *47*, 3981–3992.

52. Park, S.E.; Moon, W. Unsupervised classification of scattering mechanisms in polarimetric SAR sata using fuzzy logic in entropy and Alpha Plane. *IEEE Trans. Geosci. Remote Sens.* **2007**, *45*, 2652–2664.

© 2014 by the authors; licensee MDPI, Basel, Switzerland. This article is an open access article distributed under the terms and conditions of the Creative Commons Attribution license (<http://creativecommons.org/licenses/by/3.0/>).



# C

## Annexe 3

Journal of  
**Applied Remote Sensing**

RemoteSensing.SPIEDigitalLibrary.org

**Identification of grassland  
management practices from leaf area  
index time series**

Pauline Dusseux  
Xing Gong  
Laurence Hubert-Moy  
Thomas Corpetti

**SPIE.**

# Identification of grassland management practices from leaf area index time series

Pauline Dusseux,<sup>a,\*</sup> Xing Gong,<sup>a,b</sup> Laurence Hubert-Moy,<sup>a</sup> and Thomas Corpetti<sup>a,b</sup>

<sup>a</sup>University Rennes 2, LETG Rennes COSTEL, UMR CNRS 6554 OSU, Place du recteur Henri Le Moal, Rennes Cedex 35 043, France

<sup>b</sup>CASIA—Chinese Academy of Sciences, Institute of Automation, ZhongGuanCun Dong Lu, Beijing 100190, China

**Abstract.** The main objective of this study is to identify grassland management practices using time series of remote sensing images. The accelerating agricultural intensification has strongly reduced grassland surfaces in some areas, generating important changes in their management and affecting environmental and socio-economic systems. Therefore, the identification of grassland management practices in farming systems is a key issue for sustainable agriculture. To this end, the leaf area index (LAI) estimated from remote sensing images was used since its temporal evolution is informative about farming practices. We evaluate the performances of two common classification algorithms using time profiles of LAI derived from simulated data and high spatial resolution satellite images. We show that they exhibit limited performances, mainly because they rely on criteria that are not suited for the comparison of time series. We then suggest the use of more advanced classification tools that work in a transformed space designed by a kernel function. We show that a kernel based on time warping measurements which are suited for the comparison of time series, perform better than classical ones based on Gaussian functions. This is a promising result for the analyzing of the future SENTINEL data that will be embedded in many time series. © 2014 Society of Photo-Optical Instrumentation Engineers (SPIE) [DOI: [10.1117/1.JRS.8.083559](https://doi.org/10.1117/1.JRS.8.083559)]

**Keywords:** grasslands; high spatial resolution images; leaf area index; time series; temporal matching criteria; time warping.

Paper 14177 received Mar. 25, 2014; revised manuscript received Aug. 1, 2014; accepted for publication Aug. 11, 2014; published online Sep. 2, 2014.

## 1 Introduction

### 1.1 Identification of Grassland Practices: Interests of Remote Sensing

Because of agriculture intensification during the past 50 years, an important decrease in grassland surfaces has been observed in many regions of the Earth.<sup>1,2</sup> This affects environmental systems in different ways, ranging from water pollution increase and soil degradation to biodiversity loss,<sup>3,4</sup> and socio-economic systems for winter fodder. In addition, the functional role of grasslands (nitrogen and carbon storage) changes with agricultural practices and this affects environmental behavior. For example, carbon storage decreases with land cover changes from grassland to crop or with overgrazing.<sup>5,6</sup>

In this context, the identification of agricultural practices on grassland in farming systems, such as grazing and mowing, is of prime importance for environmental protection and sustainable agriculture. However, at the moment, no complete inventory of grassland surfaces in agricultural areas is accessible; as a result, the spatiotemporal distribution of the various types of farming practices that can be encountered on grasslands is still largely unknown. To address this issue, remote sensing appears to be an appealing solution. Grasslands can indeed be identified

---

\*Address all correspondence to: Pauline Dusseux, E-mail: [pauline.dusseux@gmail.com](mailto:pauline.dusseux@gmail.com)

0091-3286/2014/\$25.00 © 2014 SPIE

over large areas using satellite images in retrieving physical parameters related to vegetation such as vegetation density, crop height, and biomass.<sup>7,8</sup> Moreover, there is a great interest in using remote sensing images to identify and characterize the grassland management practices from a local to a regional scale, because of their high level of diversity (mowing, grazing rotation, fertilization, etc.).<sup>9,10</sup> Yet, monitoring grassland management with remote sensing is still limited both by the low revisit frequency of high spatial resolution sensors and the low spatial resolution of high revisit frequency sensors. In cloudy regions, only one or two high spatial resolution images per year are generally usable. Therefore, most temporal studies realized on grasslands management with such data have until now been limited to analyzing their interannual evolution and aim mainly toward determining their duration and status.<sup>11–13</sup> The higher time resolution of moderate spatial resolution sensors provides scope for interesting studies concerning vegetation state, but their limited spatial resolution does not allow agricultural practices to be studied at a field scale in intensive agricultural areas of fragmented landscapes.<sup>14,15</sup> Only future generations of high spatial and temporal resolution sensors (such as SENTINEL-2) will enable the identification of some agricultural practices. In view of this, in order to anticipate the upcoming data processing, it is still of prime importance to evaluate the efficiency of existing classification tools and to propose new ones to identify grassland management practices, despite the actual lack of data.

At the moment, most studies on vegetation dynamics rely on the analysis of normalized difference vegetation index (NDVI) series. However, the NDVI index suffers from many drawbacks: NDVI is sensitive to the soil background and to the atmosphere.<sup>16–19</sup> Moreover, several studies have shown that since NDVI values, which are calculated from measurements in the visible and near-infrared wavebands, depend on sensor characteristics (spectral bands width, orbital position, etc.) and the recording system.<sup>20–23</sup> Several studies have also demonstrated non-linear relationships between NDVI and vegetation properties.<sup>19,24–26</sup> According to Huete et al.,<sup>27</sup> the relationship is poor during periods of maximum leaf area index (LAI), apparently due to the saturation of NDVI at high values of LAI (over densely vegetated areas). Finally, it has been shown that for a fractional vegetation cover above 60%, vegetation indices using the near-infrared channel are almost insensitive to changes related to vegetation.<sup>28–31</sup>

A contrario, biophysical parameters such as the LAI have proven to be very efficient and suitable for vegetation monitoring, even in densely vegetated areas.<sup>7,32–34</sup> Indeed, temporal evolution of LAI is informative about vegetation growth and land management practices.<sup>35,36</sup> Thus, we suggest that the LAI series be relied on to identify grassland management practices. Although the extraction of grassland LAI from a series of remote sensing images is feasible today from a local to a global scale<sup>7,37,38</sup> (see Sec. 3.1.2), the question of discriminating farming practices on grasslands in this specific context is still challenging due to the specificity of the resulting time series that limits the efficiency of standard classification algorithms.

## 1.2 Classification of Remote Sensing Time Series

Many strategies exist to classify data from samples, ranging from the most common algorithms based on the nearest neighborhood or the maximum likelihood to advanced techniques either working in transformed spaces<sup>39–41</sup> or dedicated to complex data.<sup>41–44</sup> Up until now, apart some specific applications,<sup>45</sup> most existing remote sensing time series analysis techniques have concatenated the different two-dimensional images into one single three-dimensional image (the third dimension being time) and have analyzed this resulting image with generic tools<sup>46–49</sup> without making any allowances for the temporal aspect. Such techniques perform efficiently but, however, do not take into account the specificity of the time series. Another family of methods includes the temporal aspect by computing some criteria between successive images (combinatorial operations, linear relations, or similarity measurements) in order to reveal temporal patterns.<sup>50–53</sup> This strategy can be repeated several times in order to highlight more temporal links than that found in two successive data. Here again, the temporal property of the time series is only partly explored. Finally, some authors have also worked on the analysis of the frequential patterns (most important patterns, Fourier or wavelet transformations, etc., see Refs. 54–58) that appear in remote sensing time series. Although efficient, such techniques cannot be fully used for optical remote sensing time series data since this type of data suffer from a lack of homogeneity

regarding their temporal rate (because of the presence of clouds, aerosols). In the methods mentioned above, all the temporal information is only indirectly taken into account (through successive data or in a frequency domain) and none has a specific responsiveness when comparing two time series. This is not optimal since time series are obviously temporally correlated and can be seen as “similar” even if they are shifted in time or are not exactly at the same scale.

### 1.3 Comparison of Time Series

In this context, several criteria have been designed to compare two time series  $\mathbf{t}_1 = [t_{11}, \dots, t_{1N}]^T$  and  $\mathbf{t}_2 = [t_{21}, \dots, t_{2N}]^T$ . Even if the usual  $L_2$ -norm:  $\|\mathbf{t}_1 - \mathbf{t}_2\| = \sqrt{\sum_i (t_{1i} - t_{2i})^2}$  is often used, other measurements may be better suited to the specificity of a time series. As a consequence, measurements based on time warping (TW), such as the well-known dynamic time warping (DTW) similarity criterion introduced 20 years ago for data mining,<sup>59</sup> really represent interesting solutions. The idea behind TW is to warp one time series to another by defining some paths on which it is possible to derive some matching measurements that highlight differences in terms of temporal patterns. For example, DTW extracts an optimal path and computes a cost along this path. It constitutes an interesting solution and DTW has already been widely used for classification, clustering or even outlier detection in various domains such as speech recognition, gene analysis, word recognition, etc.,<sup>60–64</sup> but is not widely exploited in remote sensing except in recent specific studies.<sup>45,65</sup>

The main objective of this study is to identify grassland management practices using a time series of remote sensing images. For that purpose, we first generate an LAI time series and classified them with two standard algorithms: K-nearest neighbors (KNN) and support vector machine (SVM) on which we embed criteria based on TW. Roughly, the KNN technique associates to a given time series the label which is in the majority among its  $K$  nearest samples in a training set while the SVM tries to estimate a nonlinear separation between classes of the training set. This will be detailed in Sec. 3.2.1. Although such algorithms are mainly designed in the prospect of future SENTINEL-2 data, we applied the presented techniques both on real-time series composed of five SPOT images acquired in 2006 and on simulated ones where some noise has been added.

## 2 Study Site and Data

### 2.1 Study Site

As for experiments on real data, the study was carried out on a catchment area of 6150 ha located in central-north Brittany, France (Fig. 1). This area, the Yar watershed, is characterized by relatively intensive farming, mainly oriented toward cattle production, with the main crops being produced in relation to industrial breeding, principally corn, wheat, and artificial grasslands. High nitrogen rates in rivers, largely due to crop and grassland management practices, have been observed for several years at this site.<sup>66–68</sup> Thus, this watershed has been intensively monitored since the 1990s by several research teams, including scientists in agronomy, hydrology, and geography. Grasslands cover approximately 2300 fields, i.e., 60% of the total vegetation area of the watershed, with the average field size of grasslands being 0.85 ha. Three types of grassland management are encountered in this area, namely grazing, mowing and mixed management (grazing and mowing). These farming practices have different environmental effects: the biodiversity of the plant species in the grassland area and water quality are affected by overgrazing and the consequent soil erosion, while mowing is far less invasive.

### 2.2 Materials

A series of five satellite images acquired from Quickbird 2 and different SPOT sensors during the vegetation period of the year 2006 was used to identify grassland management practices (Table 1).

In parallel with image acquisition, field campaigns were conducted monthly on the watershed in 2006 during the growing season for classification calibration and validation (the maximum gap between on site measurement and image acquisition was 5 days). The percent fraction of

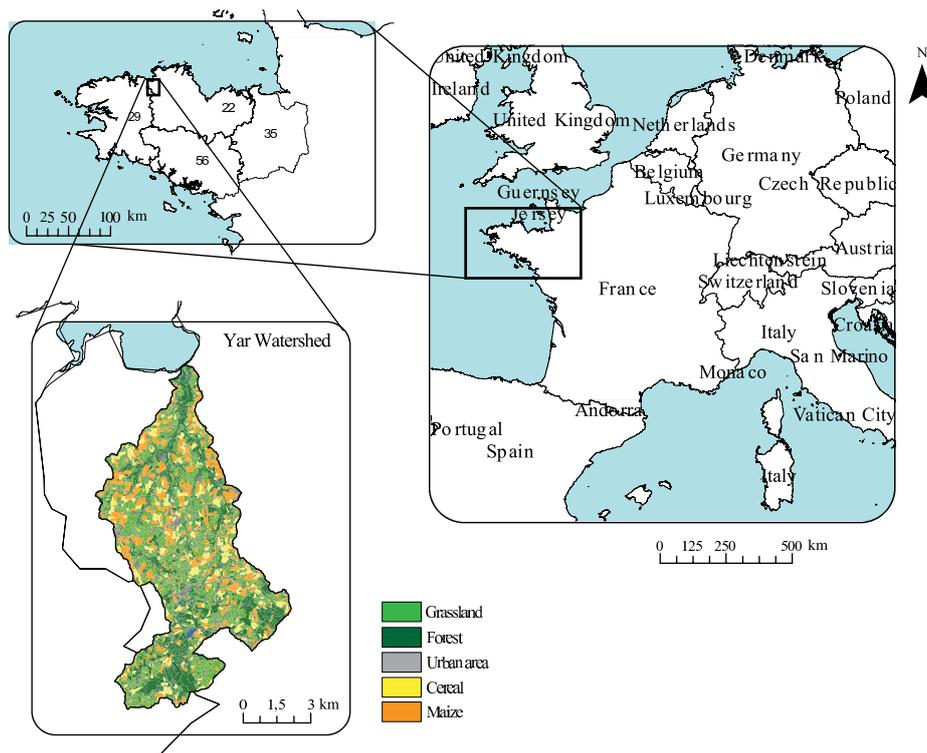


Fig. 1 Location of the study site.

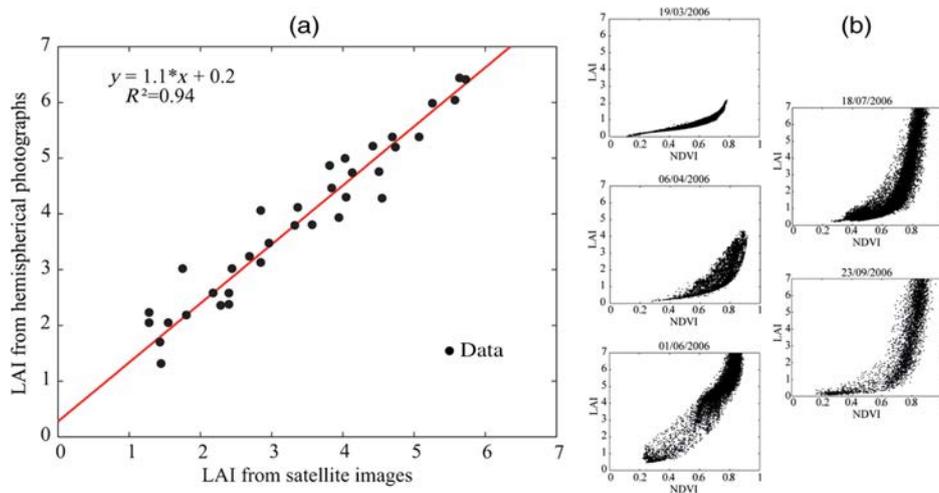


Fig. 2 Relationship between leaf area index (LAI) values derived from satellite images and LAI values estimated from hemispherical photographs acquired during the field campaigns (a); relationships between NDVI and LAI values derived from each satellite images (b).

vegetation cover, crop height, and grassland management practices were collected by averaging 150 fields distributed over the study site. Moreover, spectral signatures measured with an analytical spectral devices FieldSpec3 spectroradiometer and LAI values derived from hemispherical photographs<sup>69,70</sup> were collected on 20 of these fields. In addition, surveys were completed with volunteer farmers over four farms to assess the grassland management practices observed in the 150 fields. Among these four farms, some neighboring parcels are likely to be similarly managed. Nevertheless, because of rotational grazing applied by farmers in grasslands, they are not grazed at the same time during the year, resulting in shifted temporal profiles.

**Table 1** Characteristics of the satellite images.

Date (days of the year)	Sensor	Spatial resolution (m)	Sun elevation (deg)	Spectral bands <sup>a</sup> ( $\mu\text{m}$ )
March 19, 2006 (78)	Quickbird 2	$2.8 \times 2.8$	49.3	G/R/NIR
April 6, 2006 (96)	SPOT 2	$20 \times 20$	46.9	G/R/NIR
June 1, 2006 (152)	SPOT 5	$10 \times 10$	60	G/R/NIR/SWIR
July 18, 2006 (199)	SPOT 5	$10 \times 10$	58.7	G/R/NIR/SWIR
September 23, 2006 (266)	SPOT 4	$20 \times 20$	41.4	G/R/NIR/SWIR

<sup>a</sup>G, green; R, red; NIR, near-infrared; and SWIR, short-wavelength infrared.

**Table 2** Number of samples used for training and tests for each class.

Class	Total number of samples	Number of training samples	Number of tested samples
Grazing	1575	300	1275
Mowing	550	300	250
Mixed	1260	300	960

In practice, the total number of samples used to classify the LAI time series are shown in Table 2. One observes that the number of available samples depends on the classes. To explain this, it must be pointed out that mowing management strategy alone is, in general, less used by farmers than grazing or mixed management practices on the study site. The watershed is mainly oriented toward cattle production and it is recognized by all farmers that grazing is the cheapest way to convert grass into milk or meat. The total area of each farm is generally  $<100$  ha, so the farmers reserve their grassland acreage for grazing and surpluses are cut for silage or hay. Mixed management usually consists of a first cut in order to produce winter fodder and the paddock is then left for grazing until the end of the growing season. As a consequence, mowing alone is not required to provide winter fodder, therefore, few samples belong to this class.

### 3 Methodology

#### 3.1 LAI Temporal Profiles Computation

##### 3.1.1 Simulation of LAI

We first use the simulated time series of LAI in order to evaluate the efficiency of the classification techniques on the time series of remote sensing images comparable to future SENTINEL-2 data. These time series are simulated from growth models' functions<sup>71</sup> on which the various management practices (grazing, mowing, mixed) are applied at different time steps and to which some white Gaussian noise has been added.

The initial series is composed of 365 values for 1 year and we randomly removed 10% of the points in order to simulate the missing data that usually appear in remote sensing time series (due to clouds, aerosols, etc.). TW criteria do not require time series of the same length. For standard strategies based on the  $L_2$ -norm that require vectors of the same lengths, these missing values were linearly interpolated. In practice, we used a set of 600 simulated time series of LAI (200 for each class) related to the three management modes. Half of them were selected for training (100 for each class) and the rest for validation.

##### 3.1.2 Computation of LAI from real remote sensing data

All remote sensing data have been corrected from atmospheric and geometric effects in order to reduce errors resulting from instrumental variations in data acquisition, image noise, and

misregistration. Atmospheric corrections were performed using the 6S model<sup>72,73</sup> (Second Simulation of a Satellite Signal in the Solar Spectrum). Atmospheric conditions were estimated from the aerosol type (maritime in this case), the atmospheric model (midlatitude summer), and the aerosol optical depth (defined from moderate-resolution imaging spectrometer aerosol data and varying from 0.1 to 0.6 according to acquisition conditions). The geometric corrections were undertaken with ArcGIS 9.3 using an orthophotoplan produced by IGN (the French National Mapping Agency). All data were georeferenced based on the Lambert 2 conformal conic system.

LAI values were estimated from corrected remote sensing images using the PROSAIL radiative transfer model<sup>7,22,26</sup> which combines the SAIL and PROSPECT models. The SAIL model deals with light scattering by leaf layers with an application for canopy reflectance modeling whereas PROSPECT models leaf optical properties spectra. These models are efficient for the recovery of biophysical variables for low, medium, high, and very high resolution data.<sup>7,38,74</sup> In practice, PROSPECT simulates the canopy reflectance for a near-nadir viewing angle using several distributions known *a priori* related to canopy, leaf, and soil. More precisely:

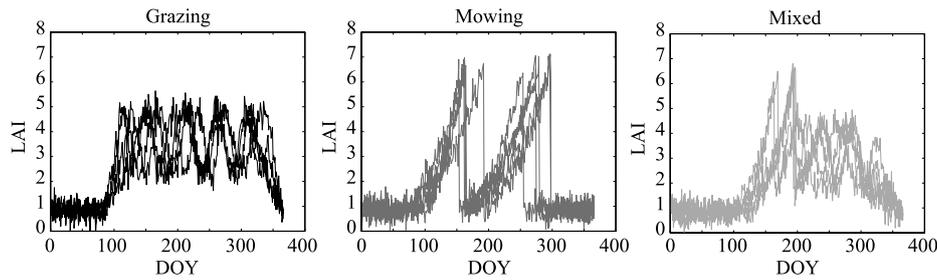
- Canopy structural parameters are leaf area angle (LAI), average leaf angle (ALA), and hotspot.
- Leaf optical properties are mesophyll structure parameter ( $N$ ), chlorophyll ( $C_{ab}$ ), dry matter ( $C_{dm}$ ), water ( $C_w$ ), and brown pigment ( $C_{bp}$ ) contents.
- Soil parameter is its reflectance [brightness coefficient ( $B_s$ )].

Once simulated, the resulting variables are used in a learning database to train a neural network in the SAIL model.<sup>74</sup> The prior distribution of all input variables required to simulate and train the PROSAIL model are described in Table 3. Soil reflectances of bare soil were acquired during the 2006/2007 winter field campaigns on the study site to obtain the  $B_s$  parameter describing the soil background reflectance. View and sun positions were supplied by the images metadata files. The variables describing canopy structure and leaf optical properties were based on backgrounds of the biological and chemical characteristics of surfaces and were defined according to the original CYCLOPES parameterization;<sup>75</sup> references are already available on the subject.<sup>38,76,77</sup> Let us mention that several studies have used similar input variable distributions on high spatial resolution data.<sup>38,78–81</sup> This enables the LAI parameter to be properly estimated, thereby providing an LAI time series.

In order to validate the LAI estimation from satellite data, hemispherical photographs acquired during the field campaigns on the study site and NDVI values from satellite data were used. A linear relationship with an  $R^2$  of 0.94 has been obtained using LAI values estimated from satellite data and from hemispherical photographs [as illustrated in Fig. 2(a)]. As can be seen in Fig. 2(b), LAI values derived from satellite images are correlated with NDVI values (also

**Table 3** Distribution characteristics of the input variables used in the learning database of the PROSAIL model.

	Variables	Min	Mean	Max	Std	Law	Class
Canopy	Leaf area index	0	2	7	—	Uniform	6
	ALA (deg)	30	60	80	20	Gaussian	4
	Hotspot	0.001	0.1	1	0.3	Gaussian	1
Leaf	$N$	1	1.5	2.5	1	Gaussian	4
	$C_{ab}$ ( $\mu\text{g cm}^{-2}$ )	20	50	90	30	Gaussian	4
	$C_{dm}$ ( $\text{g cm}^{-2}$ )	0.001	0.007	0.02	0.0045	Gaussian	4
	$C_w$	0.65	0.85	0.75	—	Uniform	4
	$C_{bp}$	0	2	0.03	0.2	Gaussian	4
Soil	$B_s$	0.1	1.5	2	0.5	Gaussian	4



**Fig. 3** Example of simulated LAI profiles used for the three classes of grassland management practices: grazing, mowing, and mixed.

computed from satellite images) but, as described in several studies,<sup>24,27,82</sup> for a fractional vegetation cover lower than 60% NDVI increases linearly with increasing LAI, while for a fractional vegetation cover higher than 60% NDVI increases very slowly with increasing LAI. This confirms the fact that LAI values derived from satellite images are better suited for vegetation cover analysis and thus are adapted to identify vegetation changes related to farming practices.

Once LAI was computed on all pixels of each image, it was averaged at the field scale, the field boundaries being delineated each year by photointerpretation using the orthophotoplan and the satellite images.

### 3.2 Data Classification

#### 3.2.1 Two standard supervised classification algorithms

Here, we suppose that a training set  $\mathcal{V} = \{(t_1, y_1), \dots, (t_N, y_N)\}$  that contains  $N$  samples of time series  $t_i = [t_{i,1}, t_{i,2}, \dots, t_{i,n}]^T$  of size  $n$  with the corresponding labels  $y_i$  is available. In practice, such a training set is issued from simulated or real data. The two state-of-the-art algorithms used for this study are KNN and SVMs.

The KNN technique<sup>83</sup> is one of the simplest classification methods. For a given proposition, its  $K$  closest samples in the training set ( $K$  being fixed by the user) are extracted. The associated label is the one that is in the majority among these  $K$  samples. The distance used to extract the  $K$  closest points has to be fixed by the user.

SVMs are originally designed for binary classification.<sup>84</sup> If the separation between the input  $t_i$  data is nonlinear, the idea is to perform the discrimination of  $\phi(t_i)$  in a transformed domain where  $\phi$  is the mapping function. It can be shown that the separability is better when the dimension of the mapping space is high. Unfortunately, a mapping function  $\phi$  of high dimension leads to computational difficulties. Therefore, one of the main ideas consists of using a so-called kernel function  $k$ : instead of defining the complete mapping  $\phi$  to perform the transformation, only the scalar product  $k(\cdot, \cdot) = \langle \phi(\cdot), \phi(\cdot) \rangle$  (i.e., the kernel) that enables a comparison between the data in the mapped space has to be known. The comparisons of the training set are defined through the kernel functions and the best separation, i.e., the largest gap between the two classes, is used as a linear discriminator. New examples to classify are then compared in the mapped space and, depending on their position with respect to the frontier, a label is assigned. From this principle, easy extensions to multilabel classifications exist.<sup>85</sup> In practice, many authors use a Gaussian kernel of the form

$$\langle \phi(t_1), \phi(t_2) \rangle = \exp(-\gamma \|t_1 - t_2\|^2), \tag{1}$$

where  $\gamma$  is the parameter to define since this kernel leads to infinite dimension spaces.

Both KNN and SVM require the computation of a criterion able to compare time series. Standard tools use the  $L_2$ -norm:  $\|t_1 - t_2\| = \sqrt{\sum_{i=1}^n (t_{1,i} - t_{2,i})^2}$  but this solution is not optimal for a time series.

### 3.2.2 TW criteria and DTW for the classification of complex time series

The standard  $L_2$ -norm does not take into account the fact that we are dealing with a time series. Temporal relations between data are neglected, sometimes yielding similar results for the comparison of different series. For example, the kernel used in SVM techniques behaves similarly when comparing two series  $(t_1, t_2)$  or each pair of series  $[\eta(t_1), \eta(t_2)]$  where  $\eta$  is any permutation function between the components of  $t_1$  or  $t_2$ . This loss of information can be prejudicial when the temporal evolution of the studied parameters is of prime importance. For this reason, it appears to be better to rely on dedicated time series matching measurements, and especially on a criterion that measures a difference on the basis of a warping from a series  $t_1$  to another  $t_2$ . In practice, to evaluate a TW criterion between series  $t_1 = [t_{1,1}, t_{1,2}, \dots, t_{1,m}]^T$  and  $t_2 = [t_{2,1}, t_{2,2}, \dots, t_{2,n}]^T$ , it is possible to compute a  $m \times n$  penalty matrix  $P$  such that each element  $P(i, j)$  represents the cost to switch from  $t_{1,i}$  to  $t_{2,j}$ . It is generally computed as

$$P(i, j) = |t_{1,i} - t_{2,j}|. \quad (2)$$

A warping path  $W = w_1, \dots, w_K, K \in [\max(m, n), m + n - 1]$  is the set of coordinates in matrix  $P$  to switch from  $P(1,1)$  to  $P(m, n)$ . It should respect the following properties:

- $w_1 = (1,1)$  and  $w_K = (m, n)$  (start and end points);
- $w_{i+1}$  is adjacent to  $w_i$  for all  $i \in [1, K - 1]$  (continuity constraint);
- $(w_{i+1} - w_i)(w_i - w_{i-1}) > 0$  for all  $i \in [2, K - 1]$  (monotonicity constraint).

Various TW criteria can be computed from such paths. For example, the well-known DTW is based on the extraction of a minimal path to switch from a series  $t_1$  to another  $t_2$ . More precisely, the DTW distance  $D_{dtw}(t_1, t_2)$  is the warping path that has the fewest cumulated penalties

$$D_{dtw}(t_1, t_2) = \min \frac{\sum_{k=1}^K P(w_k)}{K}. \quad (3)$$

Efficient implementations to find this optimal path from  $P$  can be obtained using dynamic programming. In practice, a distance matrix  $D$  of size  $m \times n$  can be constructed with  $D(1,1) = P(1,1)$  and

$$D(i, j) = \min \begin{cases} D(i - 1, j) + P(i - 1, j) \\ D(i - 1, j - 1) + P(i - 1, j - 1) \\ D(i, j - 1) + P(i, j - 1) \end{cases}. \quad (4)$$

Any value  $D(i, j)$  gives the DTW distance between the  $i$  first elements of  $t_1$  and the  $j$  first elements of  $t_2$  [and therefore, the DTW distance is  $D_{dtw}(t_1, t_2) = D(m, n)$ ].

In this study, TW criteria are embedded in some classification tools. First, two algorithms based on DTW in Eq. (3) are designed. Second, another technique, based on the whole warping paths  $w$  between two series  $t_1$  and  $t_2$ , is exploited. This yields three strategies for time series classification

1. DTW in a KNN framework. Here, the DTW measurement  $D_{dtw}(t_1, t_2)$  replaces the usual  $L_2$ -norm in a nearest neighbor framework. This technique will be referred to as  $KNN_{dtw}$ .
2. DTW in a standard SVM kernel. Here, the DTW measurement  $D_{dtw}(t_1, t_2)$  replaces the usual  $L_2$ -norm in the Gaussian kernel of relation. The new kernel now reads<sup>86-88</sup>

$$k(t_1, t_2) = \langle \phi(t_1), \phi(t_2) \rangle = \exp[-\gamma D_{dtw}^2(t_1, t_2)], \quad (5)$$

$\gamma$  being the parameter to be set. This technique will be referred to as  $SVM_{dtw}$  in the rest of this paper.

3. Global alignment kernel in an SVM technique. The kernel is still based on warping paths but in a different way than was previously done. It is proven that the kernel in Eq. (5) suffers from some theoretical drawbacks, mainly because it is not positive, definite, and symmetrical<sup>88-90</sup> and, therefore, does not respect the basic properties of kernel functions. We, therefore, suggest relying on global alignment kernels that prevent these defects. The kernel used is<sup>91,92</sup>

$$k(\mathbf{t}_1, \mathbf{t}_2) = \langle \phi(\mathbf{t}_1), \mathbf{t}_2 \rangle = \sum_{\pi \in \mathbf{w}} \prod_{i=1}^{|\pi|} g(\mathbf{t}_{\pi_{i,1}}, \mathbf{t}_{\pi_{i,2}}), \quad (6)$$

where  $\mathbf{w}$  is the set of all possible paths between series  $\mathbf{t}_1$  and  $\mathbf{t}_2$ ,  $\pi_{i,1}$  (respectively,  $\pi_{i,2}$ ) is the first (respectively, second) component of  $\pi(i)$  and  $g$  is the Gaussian function:  $g(\mathbf{t}_1, \mathbf{t}_2) = \exp(-\gamma|\mathbf{t}_1 - \mathbf{t}_2|^2)$ . It is demonstrated that this kernel is positive, definite, and symmetrical.<sup>91</sup> This technique will be referred to as SVM<sub>gak</sub> (for global alignment kernel) in the rest of this paper.

Therefore, in this study, we will compare these three strategies based on TW with the two standard algorithms presented above in order to evaluate the importance of such matching measurements for the classification of complex series issued from remote sensing data. All internal parameters (the number on the neighbor in KNN,  $\gamma$  in SVM) are estimated by  $k$ -fold cross-validation:<sup>93</sup> the training sample is randomly partitioned into  $k$  equal size subsamples. The classification process was applied on a set of varying parameters where  $k - 1$  subsamples were used as training data and the remaining one was used for validation. This process was repeated by changing the training/validation subsamples and the optimal parameter combination was retained. Cross-validation is a common and sound procedure for fixing the parameters in classification processes.

### 3.2.3 Classification assessment

To evaluate the efficiency of the classification techniques, the Kappa index was computed<sup>94,95</sup>

$$\kappa = \frac{P_g - P_m}{1 - P_m}, \quad (7)$$

where  $P_g$  is the overall rate of good classification:  $P_g = \sum_{i=1}^C M_{ii}/N$  with  $M_{ii}$  the number of samples issued from class  $i$  correctly classified,  $N$  is the total number of samples, and  $C$  is the number of classes. The component  $P_m = \sum_{i=1}^C T1(i)T2(i)/N^2$  is the ratio of marginals and is computed using  $T1(i) = \sum_{k=1}^C M_{ik}$  with  $M_{ik}$  the number of samples issued from class  $j$  and affected to class  $k$ .  $T2(i) = \sum_{k=1}^C M_{ki}$  with  $M_{ki}$  the number of samples issued from class  $k$  and assigned to class  $i$ . The kappa index provides information on the quality of the classification technique and takes into account the underestimation and overestimation errors. Generally, it is assumed that a value of  $\kappa$  higher than 0.8 is an excellent classification, values higher than 0.6 are acceptable, values higher than 0.4 have moderate accuracy, and values under 0.4 have poor agreement.

## 4 Results and Discussion

### 4.1 LAI Profiles

#### 4.1.1 Simulated temporal LAI profiles

Some illustrations of simulated temporal data are visible in Fig. 3. In this figure, one can observe that all series of a given class have similar patterns, but they do not exactly match in each time step. Such asynchronous profiles aim at simulating future time series that will be available with upcoming satellites, in particular SENTINEL-2.

Grassland management relies on grassland growing that depends mainly on climate and soil conditions, with mild temperate weather with deep rich soils as the most favorable growing conditions. Grass hardly grows when the temperature is below 5°C, but grows vigorously in the warm wet conditions that characterize the April, May, and June period in north-western Europe. During this early summer, the grass growth is generally higher than livestock requirements and farmers can exploit it to allocate a fraction of grasslands for the production of silage or hay in order to provide winter fodder for the animals. Later in the summer, a higher percentage of grassland areas are grazed for the production of milk or meat. This management strategy corresponds to the mixed management approach [Fig. 3(c)]. Farmers can also use grasslands

exclusively for mowing, with two or three cuts per year between the end of May and September [Fig. 3(b)]. Farmers may reserve their grassland acreage for grazing purposes exclusively throughout the growing period from March to October [Fig. 3(a)].

#### 4.1.2 Real temporal LAI profiles

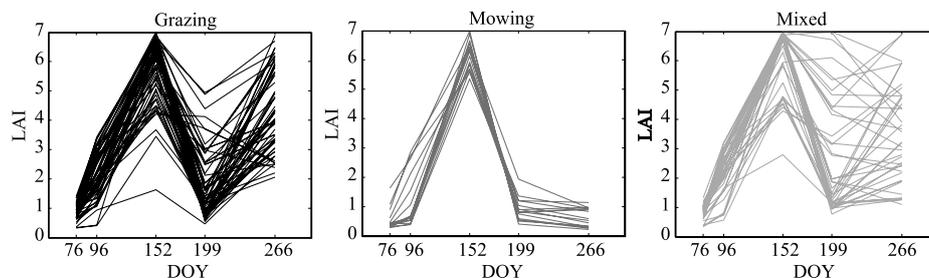
Real LAI profiles were derived from available high spatial resolution (HSR) data over year 2006, i.e., five images were acquired during the growing season at day of year (DOY) 76, 96, 152, 199, and 266. Therefore, in this specific situation, we dealt with multitemporal data rather than with dense time series. We nevertheless tested our algorithms on these data in order to evaluate the ability of TW criteria on smaller series. The extracted time series of LAI are depicted in Fig. 4. As in Fig. 3, the three management practices are identifiable. However, due to the small number of data, only some important patterns are visible:

- the two first images, issued from DOY 76, 96 (i.e., at the beginning of the growth period) yield low LAI values;
- the next image is issued from the highest growth period (DOY 152) and this peak is identifiable;
- the last two (DOY 199, 266) produce values that depend on the grassland managements.

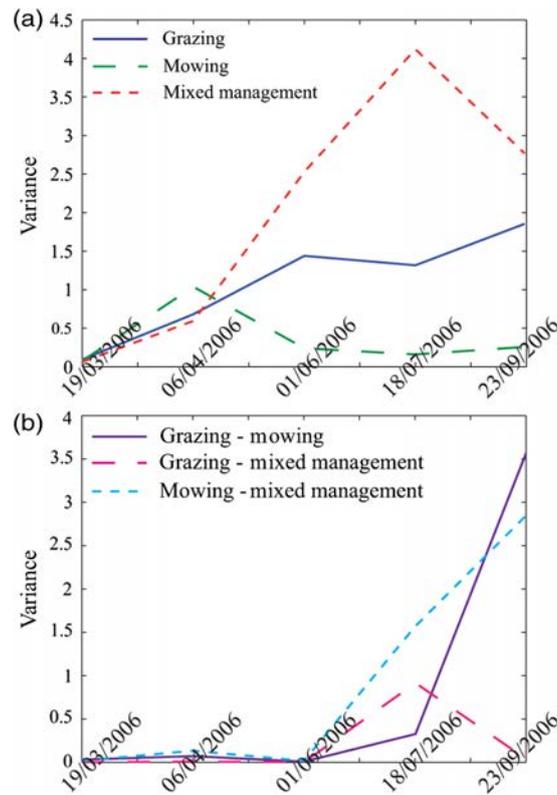
It should be noted that the gap between DOY 152 and DOY 199 is large enough to miss important information because the second growth pattern in the mowing mode [Fig. 4(b)] only shows one peak. Therefore, the series in Fig. 4 can be considered a strong subsampling set of the series in Fig. 3. Grazing, mowing, and mixed management practices show very similar behaviors for March and April corresponding to the vegetation growth period. In addition, while the mixed management LAI time series exhibits a wider spread from the average (data are spread out over a large range of LAI values especially in June, July, and September), the mowing LAI time series shows a low standard deviation. Finally, the mowing LAI time series globally exhibits more abrupt changes after management practices during the growing season.

To go into more detail on the analysis of these series, Fig. 5(a) depicts the variance of the time series data and illustrates that the LAI time series associated with grazing and mixed management practices embed a low intraclass variance in March and April, but a high intraclass variance in June, July, and September. On the contrary, the mowing LAI time series shows low intraclass variance in March, June, July, and September, and a much higher intraclass variance in April. The interclass variance graphs [Fig. 5(b)] highlight higher values of LAI from June. Moreover, September seems to be the best month to separate grazing from mowing and mowing from mixed management practices. On the other hand, July seems to be the best month to separate grazing from mixed management practices. This appears to be consistent since before spring, the vegetation is low for all management practices. In fact, intraclass and interclass variances underscore the seasonality of vegetation growth according to grassland management practices.

The LAI was retrieved from remote sensing data using a radiative transfer model, because these models, although more complex, have proven to be more informative than vegetation indices. The combined leaf (PROSPECT) and canopy (SAIL) radiative transfer model, PROSAIL,



**Fig. 4** Example of LAI profiles used for the three classes of grassland management practices: grazing, mowing, and mixed. (March, DOY: 76; April, DOY: 96; June, DOY: 152; July, DOY: 199; September, DOY: 266.)



**Fig. 5** Illustration of (a) intraclass variance and (b) interclass variance over time.

was already successfully investigated for crop studies.<sup>7,37</sup> In the context of the preparation of the future generation of sensors with high spatial and temporal resolutions, several recent studies explored the potential and limitations of using radiative transfer models such as PROSAIL<sup>96-98</sup> or the red-edge spectral bands<sup>99,100</sup> of the forthcoming superspectral satellites, namely Vegetation and Environmental Newmicro Spacecraft (VEN $\mu$ S) and SENTINEL-2, for assessing the LAI in field crops. These studies confirm that, as for any other inversion strategy, the approach used to retrieve LAI requires a radiative transfer model well suited for the crop under study. The approach developed in this study to identify grassland management practices from SPOT images will be assessed as soon as data of the forthcoming superspectral satellites are available.

## 4.2 Classification Accuracies

### 4.2.1 Simulated profiles classification

The classification accuracy of simulated profiles is shown in Table 4. When analyzing these results, it is first interesting to observe that the global accuracy of the usual two algorithms (without any temporal care for comparison of the time series) is low since the highest Kappa value is 0.65. Obviously here, the fact that the time series are shifted in time generates large errors when using conventional criteria (such as  $L_2$ -norm). It is important to remember that the series we are dealing with, even if they exhibit similar patterns for each class, are very difficult to discriminate on the basis of a date per date comparison and it appears obvious that a method based on the temporal patterns would be more suitable. When using more advanced criteria specifically based on time series measurements, the benefit is immediate. A simple KNN technique enables the results to be improved and it is worth noting that the improvements are significant with SVM<sub>dtw</sub> and even more with SVM<sub>gak</sub> with a kappa of 0.93 (bold value in the Table 4), which is totally satisfactory. Therefore, on this complete database, these experiments show the ability of TW matching measurements and specific kernels based on TW to correctly separate complex time

**Table 4** Classification accuracies of the algorithms on the simulated dataset (class 1: grazing, class 2: mowing, and class 3: mixed).

Technique		Without temporal measurements (%)		With temporal measurements (%)		
		KNN	SVM	KNN <sub>dtw</sub>	SVM <sub>dtw</sub>	SVM <sub>gak</sub>
Class 1	Well classified	80	100	91	93	87
	Omission error	20	0	9	7	13
	Commission error	0	151	4	0	0
Class 2	Well classified	51	20	76	80	100
	Omission error	49	80	24	20	0
	Commission error	0	0	11	0	0
Class 3	Well classified	100	71	85	98	100
	Omission error	0	29	15	2	0
	Commission error	69	0	40	27	13
Overall kappa		0.65	0.24	0.72	0.86	<b>0.93</b>

series such as those we are dealing with. This result is very promising, particularly with the objective of to manipulating future SENTINEL time series.

#### 4.2.2 Real profiles classification

The performances and Kappa index of the tested techniques are presented in Table 5. KNN performs better when no temporal matching criterion is taken into account. The fact that KNN makes no assumptions about any mathematical property of the samples can explain this observation. On the contrary, with the SVM procedure, a nonlinear separator is searched

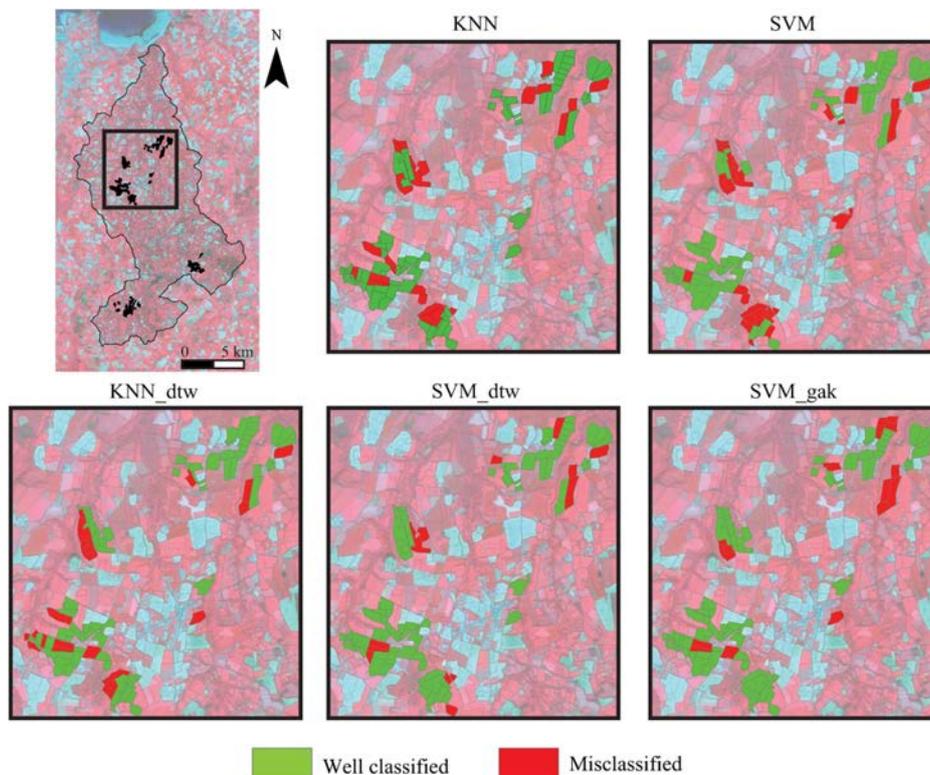
**Table 5** Classification accuracies of the algorithms on the real dataset (class 1: grazing, class 2: mowing, and class 3: mixed).

Technique		Without temporal measurements (%)		With temporal measurements (%)		
		KNN	SVM	KNN <sub>dtw</sub>	SVM <sub>dtw</sub>	SVM <sub>gak</sub>
Class 1	Well classified	95	100	84	88	86
	Omission error	5	0	16	12	14
	Commission error	17	28	11	5	4
Class 2	Well classified	60	60	78	84	86
	Omission error	40	40	22	16	14
	Commission error	0	0	0	0	0
Class 3	Well classified	71	43	86	94	95
	Omission error	29	57	14	6	5
	Commission error	23	25	24	17	18
Overall kappa		0.69	0.54	0.72	<b>0.83</b>	0.82

and since no optimal solution exists on the basis of the  $L_2$ -norm, the separator has no real significance, leading to poor results.

If one now observes the results obtained with  $KNN_{dtw}$ ,  $SVM_{dtw}$ , and  $SVM_{gak}$  it is of prime importance to note that the performances are still competitive even in these situations (few data, major visual confusion between classes, etc.), in particular with kernel-based techniques since the overall kappa is 0.82 and 0.83 (bold value in the Table 5). Here, even in this poor situation with complex data, the fact that matching measurements based on TW are more suitable than the  $L_2$ -norm to more correctly segregate complex time series patterns enables the associated techniques to achieve good performances. In our opinion, this is a good property that now enables access to very precise information (such as the agriculture management strategy) from a noisy series of HSR data.

Using classification accuracies (Table 5), we can observe that class 3 (mixed) is generally overestimated compared to classes 1 (grazing) and 2 (mowing), especially with algorithms without temporal measurement. Well classified and misclassified fields are presented in Fig. 6 for KNN, SVM,  $KNN_{dtw}$ ,  $SVM_{dtw}$ , and  $SVM_{gak}$  classification techniques. As illustrated in Table 5, class 2 (mowing) is globally underestimated in favor of class 3 (mixed) for up to 40% of the total mowing sampling using KNN and SVM algorithms without temporal measurements. Class 3 is underestimated in favor of class 1 (grazing) up to 29% using KNN and 57% using SVM without temporal measurements. To a lesser extent, using KNN and SVM algorithms with temporal measurements, classes 1 and 2 are globally underestimated in favor of class 3 up to 16%, 12%, and 14% for class 1 and 22%, 16%, and 14% for class 2 for  $KNN_{dtw}$ ,  $SVM_{dtw}$ , and  $SVM_{gak}$ , respectively. Class 3 is underestimated in favor of class 1 up to 14%, 6%, and 5% for  $KNN_{dtw}$ ,  $SVM_{dtw}$ , and  $SVM_{gak}$ , respectively. As can be observed, the use of TW criteria enables a great improvement, as shown with the algorithm  $SVM_{gak}$ . These visual observations are consistent with quantitative values and confirm the benefits of TW criteria for the identification of grassland management practices.



**Fig. 6** Illustration of classification results: extract on the study site using KNN, SVM,  $KNN_{dtw}$ ,  $SVM_{dtw}$ , and  $SVM_{gak}$  algorithms.

## 5 Conclusion

Grassland management identification is an important and sensitive issue due to its impact on the environment. Its monitoring with remote sensing tools is of great interest. In this study, we have analyzed the performances of two standard classification techniques (KNN and SVM) and three techniques based on TW criteria for grassland management identification performed on a real-time series composed of five SPOT images acquired during the same year and on a simulated set including 60 images for that particular year. The algorithms were applied on an LAI time series. Although all series present some temporal discontinuities, such as the ones encountered in our applications, standard algorithms completely fail, whereas techniques based on TW greatly improve the overall accuracy of the results. SVM<sub>dtw</sub> and SVM<sub>gak</sub> produce very satisfactory results both on simulated and real data obtained from a short series of high resolution remote sensing images.

It is of prime importance to point out that although the application illustrated in this paper concerns grassland management, the methodology introduced in this paper can be reproduced to retrieve any type of agricultural practice, as long as they can be characterized with a temporal profile. The benefit of using measurements adapted to a time series enables us to properly compare curves issued from different agricultural fields that likely to exhibit strongly asynchronous patterns, unlike usual measurement criteria (as the  $L_2$ -norm) do. Therefore, such temporal kernels can be used in any supervised or unsupervised technique related to time series analysis. This is, in our opinion, a very interesting result with a prospect for analyzing the future SENTINEL-2 data.

## Acknowledgments

This work was supported by the ANR Systerra Acastya program (ANR-08-STRA-01). The authors would like to thank Françoise Vertes, Martine Guérif, and Rémi Lecerf for fruitful discussions and precious help about grasslands and biophysical variable estimation.

## References

1. A. Peeters, "Importance, evolution, environmental impact and future challenges of grasslands and grassland-based systems in Europe," *Grassl. Sci.* **55**(3), 113–125 (2009).
2. I. Poudevigne and D. Alard, "Landscape and agricultural patterns in rural areas: a case study in the Brionne Basin, Normandy, France," *J. Environ. Manage.* **50**(4), 335–349 (1997).
3. P. Batáry, A. Báldi, and S. Erdős, "Grassland versus non-grassland bird abundance and diversity in managed grasslands: local, landscape and regional scale effects," *Biodiversity Conserv.* **16**(4), 871–881 (2007).
4. F. Vertès et al., "Short-term and cumulative effects of grassland cultivation on nitrogen and carbon cycling in ley-arable rotations," in *Grassland Science in Europe*, Ghent, Belgium, pp. 227–246 (2007).
5. E. Jérôme et al., "Impact of grazing on carbon dioxide exchanges in an intensively managed Belgian grassland," *Agric. Ecosyst. Environ.* **194**, 7–16 (2014).
6. D. Arrouays, W. Deslais, and V. Bateau, "The carbon content of topsoil and its geographical distribution in France," *Soil Use Manage.* **17**(1), 7–11 (2001).
7. S. Jacquemoud et al., "PROSPECT+SAIL models: a review of use for vegetation characterization," *Remote Sens. Environ.* **113**(Suppl. 1), S56–S66 (2009).
8. G. Rondeaux, M. Steven, and F. Baret, "Optimization of soil-adjusted vegetation indices," *Remote Sens. Environ.* **55**(2), 95–107 (1996).
9. X. Guo, "Measuring spatial and vertical heterogeneity of grasslands using remote sensing techniques," *J. Environ. Inf.* **3**(1), 24–32 (2004).
10. K. P. Price, X. Guo, and J. M. Stiles, "Optimal landsat TM band combinations and vegetation indices for discrimination of six grassland types in eastern Kansas," *Int. J. Remote Sens.* **23**(23), 5031–5042 (2002).
11. C. M. Girard et al., "SPOT HRV data to discriminate grassland quality," *Int. J. Remote Sens.* **11**(12), 2253–2267 (1990).

12. P. Doraiswamy, A. Stern, and B. Akhmedov, "Crop classification in the U.S. corn belt using MODIS imagery," in *Proc. of IEEE Int. Geoscience and Remote Sensing Symposium (IGARSS'07)*, Barcelona, Spain, pp. 809–812 (2007).
13. K. J. Wessels et al., "Mapping regional land cover with MODIS data for biological conservation: examples from the greater Yellowstone ecosystem, USA and Pará State, Brazil," *Remote Sens. Environ.* **92**(1), 67–83 (2004).
14. R. Lecerf et al., "Monitoring land use and land cover changes in oceanic and fragmented landscapes with reconstructed MODIS time series," in *Proc. of the Third Int. Workshop on the Analysis of Multi-temporal Remote Sensing Images, Multitemp*, pp. 195–199, Biloxi, Mississippi (2005).
15. X. Zhang et al., "Monitoring vegetation phenology using MODIS," *Remote Sens. Environ.* **84**(3), 471–475 (2003).
16. L. M. Montandon and E. E. Small, "The impact of soil reflectance on the quantification of the green vegetation fraction from NDVI," *Remote Sens. Environ.* **112**(4), 1835–1845 (2008).
17. G. M. Henebry, "Detecting change in grasslands using measures of spatial dependence with landsat TM data," *Remote Sens. Environ.* **46**(2), 223–234 (1993).
18. F. Baret and G. Guyot, "Potentials and limits of vegetation indices for LAI and APAR assessment," *Remote Sens. Environ.* **35**(2–3), 161–173 (1991).
19. A. R. Huete, R. D. Jackson, and D. F. Post, "Spectral response of a plant canopy with different soil backgrounds," *Remote Sens. Environ.* **17**(1), 37–53 (1985).
20. Z. Jiang, "Analysis of NDVI and scaled difference vegetation index retrievals of vegetation fraction," *Remote Sens. Environ.* **101**(3), 366–378 (2006).
21. J. Franke, V. Heinzl, and G. Menz, "Assessment of NDVI-differences caused by sensor specific relative spectral response functions," in *Proc. of IEEE Int. Conf. on Geoscience and Remote Sensing Symposium (IGARSS'06)*, Denver, CO, pp. 1138–1141 (2006).
22. S. Jacquemoud and F. Baret, "PROSPECT: a model of leaf optical properties spectra," *Remote Sens. Environ.* **34**(2), 75–91 (1990).
23. F. Baret, G. Guyot, and D. Major, "TSAVI: a vegetation index which minimizes soil brightness effects on LAI and APAR estimation," in *Proc. of the 12th Canadian Symposium on Remote Sensing and IGARSS'89*, Vol. 3, pp. 1355–1358, Cairo, Egypt (1989).
24. A. Edirisinghe et al., "Quantitative mapping of pasture biomass using satellite imagery," *Int. J. Remote Sens.* **32**(10), 2699–2724 (2011).
25. A. Viña et al., "Comparison of different vegetation indices for the remote assessment of green leaf area index of crops," *Remote Sens. Environ.* **115**(12), 3468–3478 (2011).
26. T. N. Carlson and D. A. Ripley, "On the relation between NDVI, fractional vegetation cover, and leaf area index," *Remote Sens. Environ.* **62**(3), 241–252 (1997).
27. A. R. Huete et al., "A comparison of vegetation indices over a global set of TM images for EOS-MODIS," *Remote Sens. Environ.* **59**(3), 440–451 (1997).
28. A. A. Gitelson et al., "Novel algorithms for remote estimation of vegetation fraction," *Remote Sens. Environ.* **80**(1), 76–87 (2002).
29. E. P. Glenn et al., "Relationship between remotely-sensed vegetation indices, canopy attributes and plant physiological processes: what vegetation indices can and cannot tell us about the landscape," *Sensors* **8**(4), 2136–2160 (2008).
30. J. Wu, D. Wang, and M. E. Bauer, "Assessing broadband vegetation indices and QuickBird data in estimating leaf area index of corn and potato canopies," *Field Crops Res.* **102**(1), 33–42 (2007).
31. B. M. Diaz and G. A. Blackburn, "Remote sensing of mangrove biophysical properties: evidence from a laboratory simulation of the possible effects of background variation on spectral vegetation indices," *Int. J. Remote Sens.* **24**(1), 53–73 (2003).
32. C. Zhang and X. Guo, "Monitoring northern mixed prairie health using broadband satellite imagery," *Int. J. Remote Sens.* **29**(8), 2257–2271 (2008).
33. X. Guo, K. P. Price, and J. M. Stiles, "Biophysical and spectral characteristics of cool- and warm-season grasslands under three land management practices in eastern Kansas," *Nat. Resour. Res.* **9**(4), 321–331 (2000).
34. M. A. Friedl et al., "Estimating grassland biomass and leaf area index using ground and satellite data," *Int. J. Remote Sens.* **15**(7), 1401–1420 (1994).

35. S. Asam et al., "Derivation of leaf area index for grassland within alpine upland using multi-temporal RapidEye data," *Int. J. Remote Sens.* **34**(23), 8628–8652 (2013).
36. J. M. Chen and T. A. Black, "Measuring leaf area index of plant canopies with branch architecture," *Agric. For. Meteorol.* **57**(1–3), 1–12 (1991).
37. R. Darvishzadeh et al., "Inversion of a radiative transfer model for estimating vegetation LAI and chlorophyll in a heterogeneous grassland," *Remote Sens. Environ.* **112**(5), 2592–2604 (2008).
38. R. Lecerf et al., "Estimating biophysical variables at 250 m with reconstructed EOS/MODIS time series to monitor fragment landscapes," in *Proc. of IEEE Int. Geoscience and Remote Sensing Symposium (IGARSS '08)*, Vol. 2, pp. 954–957, Boston (2008).
39. G. Camps-Valls et al., "Composite kernels for hyperspectral image classification," *IEEE Geosci. Remote Sens. Lett.* **3**(1), 93–97 (2006).
40. B. Scholkopf and A. J. Smola, *Learning with Kernels: Support Vector Machines, Regularization, Optimization, and Beyond*, MIT Press, Cambridge, Massachusetts (2001).
41. J. Zhang et al., "Local features and kernels for classification of texture and object categories: a comprehensive study," *Int. J. Comput. Vision* **73**(2), 213–238 (2007).
42. L. Liu and P. Fieguth, "Texture classification from random features," *IEEE Trans. Pattern Anal. Mach. Intell.* **34**(3), 574–586 (2012).
43. T. Ojala, M. Pietikainen, and T. Maenpaa, "Multiresolution gray-scale and rotation invariant texture classification with local binary patterns," *IEEE Trans. Pattern Anal. Mach. Intell.* **24**(7), 971–987 (2002).
44. H. Sahbi, J.-Y. Audibert, and R. Keriven, "Context-dependent kernels for object classification," *IEEE Trans. Pattern Anal. Mach. Intell.* **33**(4), 699–708 (2011).
45. F. Petitjean, J. Inglada, and P. Gançarski, "Satellite image time series analysis under time warping," *IEEE Trans. Geosci. Remote Sens.* **50**(8), 3081–3095 (2012).
46. L. Bruzzone, D. Prieto, and S. Serpico, "A neural-statistical approach to multitemporal and multisource remote-sensing image classification," *IEEE Trans. Geosci. Remote Sens.* **37**(3), 1350–1359 (1999).
47. P. Howarth, J. Piwowar, and A. Millward, "Time-series analysis of medium-resolution, multisensor satellite data for identifying landscape change," *Photogramm. Eng. Remote Sens.* **72**(6), 653–663 (2006).
48. F. Melgani and L. Bruzzone, "Classification of hyperspectral remote sensing images with support vector machines," *IEEE Trans. Geosci. Remote Sens.* **42**(8), 1778–1790 (2004).
49. A. A. Nielsen, K. Conradsen, and J. J. Simpson, "Multivariate alteration detection (MAD) and postprocessing in multispectral, bitemporal image data: new approaches to change detection studies," *Remote Sens. Environ.* **64**(1), 1–19 (1998).
50. L. Bruzzone and D. Prieto, "Automatic analysis of the difference image for unsupervised change detection," *IEEE Trans. Geosci. Remote Sens.* **38**(3), 1171–1182 (2000).
51. J. Inglada and G. Mercier, "A new statistical similarity measure for change detection in multitemporal SAR images and its extension to multiscale change analysis," *IEEE Trans. Geosci. Remote Sens.* **45**(5), 1432–1445 (2007).
52. E. F. Lambin and A. H. Strahlers, "Change-vector analysis in multitemporal space: a tool to detect and categorize land-cover change processes using high temporal-resolution satellite data," *Remote Sens. Environ.* **48**(2), 231–244 (1994).
53. A. Lefebvre, T. Corpetti, and L. Hubert-Moy, "A measure for change detection in very high resolution remote sensing images based on texture analysis," in *Proc. of IEEE Int. Conf. on Image Processing (ICIP'09)*, pp. 1697–1700, Cairo, Egypt (2009).
54. L. Andres, W. Salas, and D. Skole, "Fourier analysis of multi-temporal AVHRR data applied to a land cover classification," *Int. J. Remote Sens.* **15**(5), 1115–1121 (1994).
55. T. Celik and K.-K. Ma, "Multitemporal image change detection using undecimated discrete wavelet transform and active contours," *IEEE Trans. Geosci. Remote Sens.* **49**(2), 706–716 (2011).
56. A. Julea et al., "On extracting evolutions from satellite image time series," in *Proc. of IEEE Int. Geoscience and Remote Sensing Symposium (IGARSS'08)*, Boston, MA, Vol. 5, pp. 228–231 (2008).

57. A. Julea et al., "Unsupervised spatiotemporal mining of satellite image time series using grouped frequent sequential patterns," *IEEE Trans. Geosci. Remote Sens.* **49**(4), 1417–1430 (2011).
58. F. Petitjean et al., "Analysing satellite image time series by means of pattern mining," *Lect. Notes Comput. Sci.* **6283**, 45–52 (2010).
59. D. Berndt and J. Clifford, "Using dynamic time warping to find patterns in time series," in *KDD Workshop*, pp. 359–370 (1994).
60. J. J. R. Deller, J. Proakis, and J. Hansen, *Discrete Time Processing of Speech Signals*, 1st ed., Prentice Hall PTR, Upper Saddle River, New Jersey (1993).
61. E. Keogh and C. Ratanamahatana, "Exact indexing of dynamic time warping," *Knowl. Inf. Syst.* **7**(3), 358–386 (2005).
62. P.-F. Marteau, "Time warp edit distance with stiffness adjustment for time series matching," *IEEE Trans. Pattern Anal. Mach. Intell.* **31**(2), 306–318 (2009).
63. G. Tomasi, F. Van Den Berg, and C. Andersson, "Correlation optimized warping and dynamic time warping as preprocessing methods for chromatographic data," *J. Chemom.* **18**(5), 231–241 (2004).
64. D. Zhang et al., "Time series classification using support vector machine with Gaussian elastic metric kernel," in *Proc. of the 20th Int. Conf. on Pattern Recognition (ICPR)*, Istanbul, pp. 29–32 (2010).
65. F. Petitjean, J. Inglada, and P. Gañçarski, "Clustering of satellite image time series under time warping," in *Proc. of the 6th Int. Workshop on the Analysis of Multi-temporal Remote Sensing Images, Multi-Temp.*, Trento, Italia, pp. 69–72 (2011).
66. C. Gascuel-Odoux et al., "The role of climate on inter-annual variation in stream nitrate fluxes and concentrations," *Sci. Total Environ.* **408**(23), 5657–5666 (2010).
67. M. Michel, *Pollutions diffuses: du bassin versant au littoral*, Editions Quae, IFREMER, France, 352 pp. (1999).
68. A. Ménesguen and J.-Y. Piriou, "Nitrogen loadings and macroalgal (*Ulva* sp.) mass accumulation in Brittany (France)," *Ophelia* **42**(1), 227–237 (1995).
69. S. Garrigues et al., "Intercomparison and sensitivity analysis of leaf area index retrievals from LAI-2000, AccuPAR, and digital hemispherical photography over croplands," *Agric. For. Meteorol.* **148**(8–9), 1193–1209 (2008).
70. M. Weiss et al., "Review of methods for in situ leaf area index (LAI) determination: part II. Estimation of LAI, errors and sampling," *Agric. For. Meteorol.* **121**(1–2), 37–53 (2004).
71. C. Largouët et al., "Use of timed automata and model-checking to explore scenarios on ecosystem models," *Environ. Modell. Software* **30**, 123–138 (2012).
72. E. Vermote et al., "Second simulation of the satellite signal in the solar spectrum, 6s: an overview," *IEEE Trans. Geosci. Remote Sens.* **35**(3), 675–686 (1997).
73. C. Kergomard, "Pratique des corrections atmosphériques en télédétection: utilisation du logiciel 5S-PC," *Cybergeo: Eur. J. Geogr.* **181** (2000).
74. M. Weiss et al., "LAI and fAPAR CYCLOPES global products derived from VEGETATION. Part 2: validation and comparison with MODIS collection 4 products," *Remote Sens. Environ.* **110**(3), 317–331 (2007).
75. F. Baret et al., "LAI, fAPAR and fCover CYCLOPES global products derived from VEGETATION: part 1: principles of the algorithm," *Remote Sens. Environ.* **110**(3), 275–286 (2007).
76. M. Weiss et al., "Investigation of a model inversion technique to estimate canopy biophysical variables from spectral and directional reflectance data," *Agronomie* **20**(1), 3–22 (2000).
77. J. Feret et al., "PROSPECT-4 and 5: advances in the leaf optical properties model separating photosynthetic pigments," *Remote Sens. Environ.* **112**(6), 3030–3043 (2008).
78. M. Claverie et al., "Validation of coarse spatial resolution LAI and FAPAR time series over cropland in southwest France," *Remote Sens. Environ.* **139**, 216–230 (2013).
79. G. Duveiller et al., "Retrieving wheat green area index during the growing season from optical time series measurements based on neural network radiative transfer inversion," *Remote Sens. Environ.* **115**(3), 887–896 (2011).
80. A. Bsaibes et al., "Albedo and LAI estimates from FORMOSAT-2 data for crop monitoring," *Remote Sens. Environ.* **113**(4), 716–729 (2009).

81. K. Soudani et al., "Comparative analysis of IKONOS, SPOT, and ETM+ data for leaf area index estimation in temperate coniferous and deciduous forest stands," *Remote Sens. Environ.* **102**(1-2), 161–175 (2006).
82. Z. Jiang et al., "Development of a two-band enhanced vegetation index without a blue band," *Remote Sens. Environ.* **112**(10), 3833–3845 (2008).
83. T. Cover and P. Hart, "Nearest neighbor pattern classification," *IEEE Trans. Inf. Theory* **13**(1), 21–27 (1967).
84. C. Cortes and V. Vladimir, "Support-vector networks," *Mach. Learn.* **20**(3), 272–297 (1995).
85. T. Zhang, "An introduction to support vector machines and other kernel-based learning methods," *AI Mag.* **22**(2), 103–104 (2001).
86. C. Bahlmann, B. Haasdonk, and H. Burkhardt, "Online handwriting recognition with support vector machines—a kernel approach," in *Proc. of the Eighth Int. Workshop on Frontiers in Handwriting Recognition*, Niagara-on-the-Lake, Ontario, Canada, pp. 49–54 (2002).
87. H. Shimodaira et al., "Dynamic time-alignment kernel in support vector machine," in *Advances in Neural Information Processing Systems*, Vol. 14, pp. 921–928, MIT Press, Cambridge, MA (2001).
88. D. Zhang et al., "Time series classification using support vector machine with Gaussian elastic metric kernel," in *Proc. of the 20th Int. Conf. on Pattern Recognition (ICPR'10)*, Istanbul, pp. 29–32 (2010).
89. B. Haasdonk and D. Keysers, "Tangent distance kernels for support vector machines," in *Proc. of the 16th Int. Conf. on Pattern Recognition*, Quebec City, Canada, Vol. 2, pp. 864–868 (2002).
90. H. Lei and B. Sun, "A study on the dynamic time warping in kernel machines," in *Proc. of the Third Int. IEEE Conf. on Signal-Image Technologies and Internet-Based System (SITIS'07)*, Shanghai, China, pp. 839–845 (2007).
91. M. Cuturi et al., "A kernel for time series based on global alignments," in *Proc. of IEEE Int. Conf. on Acoustics, Speech and Signal Processing (ICASSP'07)*, Honolulu, HI, Vol. 2, pp. II-413–II-416 (2007).
92. M. Cuturi, "Fast global alignment kernels," in *Proc. of the 28th Int. Conf. on Machine Learning (ICML'11)*, L. Getoor and T. Scheffer, Eds., pp. 929–936, ACM, New York (2011).
93. R. Kohavi, "A study of cross-validation and bootstrap for accuracy estimation and model selection," in *Proc. of the 14th Int. Joint Conf. on Artificial Intelligence (IJCAI'95)*, Vol. 2, pp. 1137–1143, Morgan Kaufmann Publishers Inc., San Francisco, California (1995).
94. R. G. Congalton, "A review of assessing the accuracy of classifications of remotely sensed data," *Remote Sens. Environ.* **37**(1), 35–46 (1991).
95. J. Cohen, "A coefficient of agreement for nominales scales," *Educ. Psychol. Meas.* **20**(1), 37–46 (1960).
96. K. Richter et al., "Optimal exploitation of the sentinel-2 spectral capabilities for crop leaf area index mapping," *Remote Sens.* **4**(3), 561–582 (2012).
97. C. Atzberger and K. Richter, "Spatially constrained inversion of radiative transfer models for improved LAI mapping from future sentinel-2 imagery," *Remote Sens. Environ.* **120**, 208–218 (2012).
98. K. Richter et al., "Evaluation of sentinel-2 spectral sampling for radiative transfer model based LAI estimation of wheat, sugar beet, and maize," *IEEE J. Sel. Top. Appl. Earth Obs. Remote Sens.* **4**(2), 458–464 (2011).
99. J. Delegido et al., "Evaluation of sentinel-2 red-edge bands for empirical estimation of green LAI and chlorophyll content," *Sensors* **11**(7), 7063–7081 (2011).
100. I. Herrmann et al., "LAI assessment of wheat and potato crops by VENS and sentinel-2 bands," *Remote Sens. Environ.* **115**(8), 2141–2151 (2011).

**Pauline Dusseux** received the master's degree in geography from Agrocampus Ouest and Rennes 2 University (France). Currently, she is working toward the PhD degree in geography at COSTEL Laboratory and she is also a teacher assistant at Rennes 2 University (Rennes,

France). Her main areas of research interest are both methodological and thematic, with the evaluation of time series of high spatial resolution remote sensing images for the identification of grassland and characterization of grassland management practices.

**Xing Gong** received the master's degree in pattern recognition in June 2011 from Institute of Automation, Chinese Academy of Science (CAS). Currently, he is working toward the PhD degree since October 2011 at the COSTEL Laboratory (Rennes, France) and at the Sino-French Laboratory for Computer Science, Automation, and Applied Mathematics (LIAMA, Beijing, China). His main areas of research interest are change detection, classification of temporal evolution of land cover and use based on remote-sensing data, and matrix factorization.

**Laurence Hubert-Moy** is a director assistant of the Observatory of the Sciences of the Universe of Rennes (France) (OSUR) and president of the TOSCA committee (Solid Earth, Oceans, Continental Surfaces, Atmosphere) of the CNES (French National Spatial Agency) since 2012. Her field of expertise concerns environmental applications of remote sensing and especially (1) monitoring and modeling of land cover and land use changes (2) delineation, characterization, and functional assessment of wetlands, and (3) mapping of ecological continuities.

**Thomas Corpetti** obtained his PhD degree in computer vision and applied mathematics at University Rennes I, France, in 2002. He is a senior researcher in CNRS (French National Institute for Scientific Research) working on the analysis of remote sensing images for environmental applications. From 2009 to 2012, he was in LIAMA, a sino-french lab in computer sciences and applied mathematics in Beijing, China. He is now with Observatory for Universe Sciences of Rennes, France.



# Table des figures

1	Organisation générale de la thèse . . . . .	xv
1.1	Services et avantages rendus par les prairies . . . . .	4
1.2	Illustrations de prairies permanentes (a) : prairies pâturées composées de ray-grass et trèfles, avec présence de fougères (1) et rumex (2) ; illustrations de prairies temporaires (b) : prairie pâturée, composée principalement de ray-grass (1), prairie à usage mixte, composée de ray-grass et trèfles (2) ; illustrations de prairies artificielles (c) : prairie ensemencée en trèfle violet destinée à la fauche (1) et prairie ensemencée en luzerne destinée à la fauche (2) . . . . .	5
1.3	Évolution phénologique de la prairie au cours d’une saison végétative . . . . .	7
1.4	Illustrations de prairies pâturées (a) et fauchées (b) . . . . .	9
1.5	Interaction du rayonnement électromagnétique avec la surface terrestre en télédétection passive (a) et en télédétection active (b). Principaux domaines du spectre électromagnétique (c) (E : Rayonnement incident/émis, T : transmis, A : absorbé, D : diffusé, R : réfléchi) . . . . .	12
1.6	Résolution spatiale des capteurs spatiaux d’observation de la Terre en fonctionnement ou programmés pour un lancement avant 2014 (a) et extrait d’une image GeoEye initialement à 1m de résolution, dégradée à des résolutions spatiales plus faibles (b) . . .	16
1.7	Signatures spectrales de la végétation . . . . .	19
1.8	Répartition dans l’espace rouge/proche infrarouge (a) de pixels avec et sans couverture végétale et (b) d’un pixel de végétation au cours de la saison végétative (d’après [Jensen 2000]) . . . . .	20
1.9	Images du NDVI et du LAI dérivées sur un extrait de l’image SPOT 5 du 26/06/2010	22
1.10	Principaux mécanismes de rétrodiffusion sur un couvert végétal . . . . .	25
1.11	Composition colorée d’un extrait d’une image RADARSAT-2 du 15/06/2010 à partir des intensités (VV (B), HV (V) et HH (R)) . . . . .	26
1.12	Composition colorée d’un extrait d’une image RADARSAT-2 du 15/06/2010 à partir des paramètres polarimétriques de Cloude-Pottier (Anisotropy (B), Entropy (V) et Alpha (R)) . . . . .	28
1.13	Composition colorée d’un extrait d’une image RADARSAT-2 du 15/06/2010 à partir des paramètres polarimétriques de Freeman-Durden (Double (B), Volume (V) et Surface (R)) . . . . .	28
1.14	Exemples de profils temporels intra-annuels pour des parcelles de céréales d’hiver, de maïs, et de prairies utilisées pour du pâturage, en fauche et en exploitation mixte (a) théoriques et (b) dérivés de séries d’images satellites optiques acquises en 2006, 2010 et 2011 . . . . .	30
1.15	Localisation du site d’étude . . . . .	35
1.16	Diagrammes ombrothermiques de la région du bassin versant du Yar des trois années étudiées . . . . .	36

1.17	Illustration du développement des algues vertes sur l'espace côtier de la Baie de Saint Michel-en-Grève . . . . .	36
1.18	Cartes de l'occupation des sols sur le bassin versant du Yar en 1952, 1978, 1998 et 2008 . . . . .	38
1.19	Principaux changements d'occupation des sols sur le bassin versant du Yar entre 1952 et 2008 : évolution en surfaces de l'occupation des sols (a), évolution des ratios Cultures/Prairies et Surfaces boisées/Prairies (b) et dynamique temporelle des surfaces en prairies, cultures et surfaces boisées (c) . . . . .	38
1.20	Cartes de l'occupation des sols sur le bassin versant du Yar de 1997 à 2008 . . . . .	40
1.21	Évolution des changements d'occupation des sols entre 1997 et 2008 sur le bassin versant du Yar . . . . .	40
1.22	Les dynamiques spatio-temporelles de la SAU à l'échelle parcellaire : fréquence de retour des prairies et des cultures sur la période 1997-2008 sur le bassin versant du Yar non successives (a) et successives (b). [Nombre d'années en prairies et en cultures sur la période 1997-2008 (a-1), classement des parcelles selon les types de successions culturales (a-2), cartographie des types de successions culturales (a-3), nombre d'années en prairies et en cultures successives sur la période 1997-2008 (b-1), classement des prairies selon leur durée (b-2) et cartographie (b-3)] . . . . .	42
1.23	Entrées et sorties des modèles PROSPECT et SAIL [Bacour & Jacquemoud 2001] (a) et Schéma conceptuel du modèle de transfert radiatif direct et inverse PROSPECT-SAIL (d'après [Bacour <i>et al.</i> 2003], in [Lecerf 2008]) (b) . . . . .	49
1.24	Transformation des paramètres dérivés des données de télédétection de l'échelle du pixel à la parcelle. Exemple sur un extrait de la zone d'étude représentant la variable LAI (a) et la base de données (b) . . . . .	53
1.25	Illustration de la méthode de classification KNN. Pour une nouvelle entrée donnée, les $k$ plus proches voisins (ici $k=3$ ) sont extraits et le label majoritaire parmi ces entités est associé à la nouvelle entrée (rond noir dans cet exemple) . . . . .	54
1.26	Illustration de la méthode de classification SVM. A partir d'un ensemble d'apprentissage où la séparation entre classes est non linéaire (gauche), on le transforme afin d'obtenir une séparation linéaire (droite). Un nouveau point sera affecté à une classe en fonction de sa position par rapport à la frontière . . . . .	55
1.27	Localisation des parcelles échantillonnées. Illustration de relevés d'occupation et d'utilisation des sols (a), mesures spectrales (b) et photographies hémisphériques (c) . . . . .	57
1.28	Calibration du spectro-radiomètre (à gauche) et collecte de profils spectraux (à droite) . . . . .	58
1.29	Étapes de traitement des mesures spectrales collectées <i>in situ</i> . Exemple sur deux mesures de réflectance correspondant à une prairie ayant une hauteur de végétation supérieure à 20cm et une prairie ayant une hauteur de végétation inférieure à 10cm : exclusion des valeurs situées dans les longueurs d'onde d'absorption de l'eau (a et b), calcul des moyennes des mesures spectrales par parcelle (c), lissage des mesures spectrales (d) et ré-échantillonnage des réflectances <i>in situ</i> à la résolution des images satellites SPOT (e) . . . . .	59
1.30	Étapes de traitement des photographies hémisphériques prises dans les parcelles (illustrations d'une photographie prise sur une parcelle de culture caractérisée par une hauteur de moins de 10cm avec du sol visible : étape de masquage (a) et de classification (b) . . . . .	61
2.1	Méthodologie générale appliquée pour l'évaluation de paramètres dérivés de données de télédétection optiques pour l'estimation de la biomasse . . . . .	70
2.2	Zone en défens pour la collecte de la biomasse . . . . .	73

2.3	Régressions et coefficients de détermination ( $R^2$ ) calculés entre les valeurs de NDVI, LAI et fCOVER dérivés des images de télédétection et les mesures de biomasses <i>in situ</i> (t MS/ha) . . . . .	74
2.4	Évaluation de la précision du modèle d'estimation de la biomasse à partir du LAI dérivé d'images de télédétection (t MS/ha) . . . . .	75
2.5	Spatialisation de la biomasse estimée : à partir de chaque image satellite (a), à l'échelle parcellaire sur tout le bassin versant (b), à l'échelle parcellaire pour une ferme pilote (c) et le stock d'herbe estimé pour cette ferme pilote (d) . . . . .	76
2.6	Méthodologie générale appliquée pour l'évaluation de paramètres dérivés d'images satellites optiques pour le suivi des prairies . . . . .	78
2.7	Classification des prairies selon trois états de surface : $S1$ correspondant à une végétation d'une hauteur inférieure à 10cm avec le sol apparent (taux de couverture par la végétation < 70%), $S2$ correspondant à une végétation d'une hauteur comprise entre 10cm et 20cm (taux de couverture par la végétation > 90%) et $S3$ correspondant à une hauteur de végétation supérieure à 20cm (taux de couverture = 100%) . . . . .	81
2.8	Mesures spectrales collectées avec le spectroradiomètre ASD FieldSpec3 : forme similaire des profils (a) et variabilité intra-classe (b) . . . . .	83
2.9	Mesures spectrales classées par mois d'acquisition et selon l'état de surface de la végétation ( $S1$ = état de surface 1, $S2$ = état de surface 2 et $S3$ = état de surface 3) . . . . .	83
2.10	NDVI par classe et par mois d'acquisition dérivé des mesures spectrales <i>in situ</i> . . . . .	84
2.11	LAI et fCOVER par classe et par mois d'acquisition dérivés des photographies hémisphériques prises sur le terrain . . . . .	85
2.12	Réflectances moyennes par classe et par mois d'acquisition dérivées des images satellites . . . . .	86
2.13	NDVI, LAI et fCOVER par classe et par mois d'acquisition dérivés des images satellites . . . . .	87
2.14	Régression linéaire entre les valeurs de NDVI estimées à partir des images satellites SPOT ( $NDVI_{spot}$ ) et les valeurs de NDVI dérivées des mesures spectrales <i>in situ</i> ( $NDVI_{spectral}$ ) (a); entre les valeurs de LAI estimées à partir des images satellites SPOT ( $LAI_{spot}$ ) et les valeurs de LAI dérivées des photographies hémisphériques ( $LAI_{hemis}$ ) (b); entre les valeurs de fCOVER estimées à partir des images satellites SPOT ( $fCOVER_{spot}$ ) et les valeurs de fCOVER dérivées des photographies hémisphériques ( $fCOVER_{hemis}$ ) (c) . . . . .	89
2.15	Relation entre les valeurs moyennes de NDVI, LAI et fCOVER estimées à partir des images satellites SPOT ( $NDVI_{spot}$ , $LAI_{spot}$ et $fCOVER_{spot}$ ) par classe et par mois d'acquisition (a) et relation entre les valeurs de NDVI, LAI et fCOVER estimées à partir des images satellites SPOT ( $NDVI_{spot}$ , $LAI_{spot}$ et $fCOVER_{spot}$ ) par mois d'acquisition (b). Il apparaît clairement sur ces graphiques que les relations mises en jeu sont non linéaires . . . . .	90
2.16	Profils temporels de LAI estimés à partir des photographies hémisphériques (a-1), moyenne (a-2), variance intra-classe (a-3) et inter-classe (a-4); Profils temporels de LAI estimés à partir des images satellites (a-1), moyenne (a-2), variance intra-classe (a-3) et inter-classe (a-4) . . . . .	91
2.17	Procédure et évaluation des classifications . . . . .	93
3.1	Méthodologie générale appliquée à des séries temporelles d'images optiques à haute résolution spatiale pour identifier des prairies . . . . .	102
3.2	Profils temporels de LAI correspondant aux échantillons terrain relevés pour les trois années étudiées (2006, 2010 et 2011) . . . . .	103
3.3	Valeurs de Kappa obtenues en utilisant différentes combinaisons d'images satellites pour les séries acquises en 2006, 2010 et 2011 . . . . .	110

3.4	Méthodologie générale appliquée pour identifier les prairies en utilisant de images optiques et radars . . . . .	114
3.5	Relation entre le LAI et les six paramètres dérivés des images radars pour les parcelles enquêtées en juin 2010 . . . . .	118
3.6	Profils temporels de LAI et du rapport de polarisation HH/VV pour les parcelles enquêtées	119
3.7	Stades phénologiques et pratiques agricoles pour les trois classes d'occupation des sols étudiées . . . . .	120
3.8	Représentation des trois classes d'occupation des sols dans l'espace entropie ( $H$ ) et alpha ( $\alpha$ ), variables dérivées de la décomposition de Cloude–Pottier, pour chaque date d'acquisition . . . . .	122
3.9	Représentation 3D des trois classes d'occupation des sols dans l'espace comprenant les variables volume, surface et double rebond dérivées de la décomposition de Freeman–Durden pour les cinq date d'acquisition des images radars . . . . .	123
3.10	Illustration des résultats de classification montrant les parcelles mal classées en utilisant exclusivement le LAI ou les paramètres issus de la décomposition de Cloude–Pottier et les parcelles bien classées en utilisant la combinaison du LAI et des paramètres issus de la décomposition de Cloude–Pottier . . . . .	127
3.11	Méthodologie générale appliquée pour identifier les prairies en utilisation des séries de données optiques et radars . . . . .	130
3.12	Relation entre le LAI et le coefficient de rétrodiffusion VV pour les parcelles enquêtées en en mai et août 2011 . . . . .	132
3.13	Illustration des mécanismes de diffusion en fonction du stade phénologique de la végétation pour les trois classe étudiées . . . . .	133
3.14	Profils temporels de LAI et du coefficient de rétrodiffusion VV pour les parcelles enquêtées	135
4.1	Méthodologie générale appliquée pour comparer des méthodes de classification visant à identifier les modes de gestion des prairies . . . . .	144
4.2	Illustration de la difficulté d'utiliser la norme euclidienne. Sur cette figure, la distance (au sens de la norme $L_2$ ) entre $f$ et $g$ est identique à celle entre $f$ et $h$ bien que les différences soient de nature différentes (dans un cas on a des courbes qui n'ont rien à voir, dans l'autre on a simplement un décalage temporel) . . . . .	147
4.3	Exemple de profils temporels simulés de LAI pour les trois modes de gestion des prairies : pâturage (a), fauche (b) et exploitation mixte (c) . . . . .	150
4.4	Exemple de profils temporels réels de LAI pour les trois modes de gestion des prairies : pâturage (a), fauche (b) et exploitation mixte (c) (Mars, DOY :76; Avril, DOY :96; Juin, DOY :152; Juillet, DOY :199; Septembre, DOY :266) . . . . .	150
4.5	Illustration de la variance intra-classe (a) et de la variance inter-classe (b) pour chaque date d'acquisition . . . . .	151
4.6	Profils temporels de LAI et du coefficient de rétrodiffusion HH correspondant aux parcelles enquêtées pour les trois modes de gestion . . . . .	160
4.7	Représentation des trois modes de gestion dans l'espace entropie ( $H$ ) et alpha ( $\alpha$ ), variables dérivées de la décomposition de Cloude–Pottier, pour chaque date d'acquisition	160
4.8	Représentation des trois modes de gestion dans l'espace comprenant les variables volume, surface et double rebond dérivées de la décomposition de Cloude–Pottier pour chaque date d'acquisition . . . . .	160
4.9	Profils temporels de LAI et du coefficient de rétrodiffusion VV correspondant aux parcelles enquêtées pour les trois modes de gestion . . . . .	161

## Liste des tableaux

1.1	Itinéraires techniques types des principales catégories de prairies situées en Bretagne Ouest et Centre (d'après Vertès F., communication) . . . . .	8
1.2	Caractéristiques des principaux capteurs et satellites utilisables pour l'étude des prairies en milieu agricole . . . . .	13
1.3	Exemples de successions culturales extraites de la base de données de l'occupation des sols pour la trajectoire « temps court » 1997-2008 . . . . .	41
1.4	Facteurs expliquant la dynamique spatio-temporelle des prairies . . . . .	44
1.5	Évolution des surfaces en culture et en prairie entre 2008 et 2011 sur le bassin versant du Yar . . . . .	45
1.6	Caractéristiques des images de télédétection optique utilisées . . . . .	48
1.7	Caractéristiques des variables d'entrée utilisées pour calibrer le modèle PROSAIL . . . . .	51
1.8	Caractéristiques des images de télédétection radar utilisées . . . . .	52
2.1	Dates de collecte des mesures de biomasse et dates d'acquisition des images satellites . . . . .	72
2.2	NDVI moyen par classe et par mois d'acquisition dérivé des mesures spectrales <i>in situ</i> . . . . .	84
2.3	LAI et fCOVER moyen par classe et par mois d'acquisition dérivés des photographies hémisphériques prises sur le terrain . . . . .	85
2.4	NDVI, LAI et fCOVER moyen par classe et par mois d'acquisition dérivés des images satellites . . . . .	86
2.5	Mesure de dissimilarité $D$ entre les trois classes d'état de surface pour le NDVI, LAI et fCOVER dérivés des mesures <i>in situ</i> . . . . .	88
2.6	Mesure de dissimilarité $D$ entre les trois classes d'état de surface pour le NDVI, LAI et fCOVER dérivés des images satellites . . . . .	88
3.1	Matrice de confusion entre la classification réalisée à partir des séries temporelles (lignes) et les données de référence (colonnes) (%) . . . . .	104
3.2	Paramètres descriptifs (moyenne et variance) des profils temporels de LAI acquis en 2006 . . . . .	106
3.3	Paramètres descriptifs (moyenne et variance) des profils temporels de LAI acquis en 2010 . . . . .	106
3.4	Paramètres descriptifs (moyenne et variance) des profils temporels de LAI acquis en 2011 . . . . .	106
3.5	Sous-détection, sur-détection et valeurs de Kappa pour les classifications de l'occupation des sols effectuées avec une seule date avec les données acquises en 2006 . . . . .	108
3.6	Sous-détection, sur-détection et valeurs de Kappa pour les classifications de l'occupation des sols effectuées avec une seule date avec les données acquises en 2010 . . . . .	108
3.7	Sous-détection, sur-détection et valeurs de Kappa pour les classifications de l'occupation des sols effectuées avec une seule date avec les données acquises en 2011 . . . . .	109
3.8	Valeurs de la divergence transformée ( $TD$ ) obtenues entre les trois classes d'occupation des sols pour les paramètres LAI et radars . . . . .	124

3.9	Matrices de confusion (en %) issues des classifications de l'occupation des sols utilisant la variable LAI dérivée des données optiques (a), la combinaison des polarisations HH, VV et HV, les paramètres issus de la décomposition de Freeman–Durden et les paramètres issus de la décomposition de Cloude–Pottier dérivés des données radars (b), (c) et (d), respectivement . . . . .	125
3.10	Matrices de confusion (en %) issues des classifications de l'occupation des sols utilisant la combinaison des données optiques et radars : LAI - HH, VV et HV (a), LAI - les paramètres issus de la décomposition de Freeman–Durden (b) et LAI - les paramètres issus de la décomposition de Cloude–Pottier (c) . . . . .	126
3.11	Matrices de confusion (en %) correspondant aux classification de l'occupation des sols utilisant le LAI dérivé des données optiques (a), le coefficient de rétrodiffusion VV extrait des données radars (b) et la combinaison des paramètres LAI et VV (c) . . . .	136
4.1	Performances de classification des différents algorithmes appliqués au jeu de données simulées (Classe 1 : pâturage, classe 2 : fauche et classe 3 : exploitation mixte) . . . .	152
4.2	Performances de classification des différents algorithmes appliqués au jeu de données réelles (Classe 1 : pâturage, classe 2 : fauche et classe 3 : exploitation mixte) . . . . .	153
4.3	Valeurs de la divergence transformée entre les modes de gestion des prairies pour le LAI et les paramètres radars (séries temporelles de l'année 2010) . . . . .	159
4.4	Valeurs de la divergence transformée entre les modes de gestion des prairies pour le LAI extrait des images optiques et le coefficient de rétrodiffusion HH issu des données radars pour l'année 2011 . . . . .	161
4.5	Valeurs de Kappa obtenues pour la classification des séries temporelles de LAI acquises en 2010 et en 2011 avec et sans utilisation de métriques temporelles . . . . .	162
4.6	Valeurs de Kappa obtenues pour la classification des trois paramètres dérivés de la série temporelle radar acquise en 2010 . . . . .	162
4.7	Valeurs de Kappa obtenues pour la classification du paramètre dérivé de la série temporelle radar acquise en 2011 . . . . .	162
4.8	Matrices de confusion (en %) issues des classifications utilisant la méthode de classification SVM <sub>gak</sub> et la variable LAI dérivée de séries temporelles acquises en 2010 (a) et en 2011 (b) pour identifier les modes de gestion des prairies . . . . .	163

# Table des matières

Introduction Générale . . . . .	xi
<b>1 Identification, caractérisation et suivi des prairies par télédétection</b>	<b>1</b>
1.1 Éléments de contexte . . . . .	3
1.1.1 Problématiques et enjeux de l'étude des prairies en milieu agricole . . . . .	3
1.1.2 Les prairies en milieu agricole : caractéristiques et modes de gestion . . . . .	4
1.1.2.1 Les types de prairie en secteur agricole . . . . .	4
1.1.2.2 Croissance des prairies et modes de gestion . . . . .	6
1.1.2.2.1 La croissance de l'herbe . . . . .	6
1.1.2.2.2 Les modes de gestion associés aux prairies . . . . .	6
1.1.2.2.2.1 Le pâturage . . . . .	8
1.1.2.2.2.2 La fauche . . . . .	9
1.1.2.2.2.3 L'exploitation mixte . . . . .	9
1.1.2.2.2.4 Autres modes de gestion des prairies . . . . .	10
1.2 La télédétection : potentiel pour le suivi des prairies en milieu agricole . . . . .	11
1.2.1 Caractéristiques des données de télédétection utilisables pour l'étude des prairies	11
1.2.1.1 Télédétection passive et télédétection active . . . . .	11
1.2.1.2 Les données acquises dans le domaine optique . . . . .	16
1.2.1.2.1 La résolution spatiale . . . . .	16
1.2.1.2.2 La résolution temporelle . . . . .	17
1.2.1.2.3 La résolution spectrale . . . . .	17
1.2.1.3 Les données acquises dans le domaine des hyperfréquences . . . . .	17
1.2.1.3.1 La fréquence d'émission ou longueur d'onde . . . . .	17
1.2.1.3.2 La polarisation d'émission et de réception . . . . .	18
1.2.1.3.3 L'angle d'incidence . . . . .	18
1.2.2 Télédétection et prairies : état de l'art . . . . .	18
1.2.2.1 L'usage des images satellites acquises dans le domaine optique . . . . .	18
1.2.2.1.1 La signature spectrale de la végétation . . . . .	18
1.2.2.1.2 Les données . . . . .	19
1.2.2.1.3 Les paramètres dérivés des images optiques pour le suivi des prairies . . . . .	21
1.2.2.1.3.1 Les indices de végétation . . . . .	21
1.2.2.1.3.2 Les variables biophysiques . . . . .	23
1.2.2.2 L'usage des images satellites acquises dans le domaine des hyperfréquences . . . . .	25
1.2.2.2.1 La signature spectrale de la végétation . . . . .	25
1.2.2.2.2 Les données . . . . .	26
1.2.2.2.3 Les paramètres dérivés pour le suivi des prairies . . . . .	27
1.2.2.2.3.1 Les coefficients de rétrodiffusion ( $\sigma^0$ dB) . . . . .	27
1.2.2.2.3.2 Les paramètres obtenus par décompositions polarimétriques . . . . .	27
1.2.3 Classification de séries temporelles de données de télédétection . . . . .	29
1.2.3.1 Les profils temporels . . . . .	29
1.2.3.2 Analyse de la séparabilité entre les classes . . . . .	31
1.2.3.3 Classification de séries temporelles . . . . .	32
1.3 Le site d'étude . . . . .	35
1.3.1 Caractéristiques du bassin versant du Yar . . . . .	35

1.3.2	Historique de l'occupation des sols sur le bassin versant du Yar pour déterminer la place des prairies dans les systèmes de production . . . . .	37
1.3.2.1	Évolution des prairies sur le bassin versant du Yar depuis les années 1950 (« <i>temps long</i> : de 1952 à 2008 ») . . . . .	37
1.3.2.1.1	Les données . . . . .	37
1.3.2.1.2	Analyse de la dynamique spatio-temporelle de l'occupation des sols . . . . .	37
1.3.2.2	Les prairies sur le bassin versant du Yar depuis la fin des années 1990 (« <i>temps court</i> : de 1997 à 2008 ») . . . . .	39
1.3.2.2.1	Les données . . . . .	39
1.3.2.2.2	Analyse des successions culturales et de la dynamique spatio-temporelle des prairies . . . . .	41
1.3.2.2.3	Les facteurs expliquant la dynamique spatio-temporelle des prairies . . . . .	44
1.3.2.3	La tendance des dernières années : de 2008 à 2011 . . . . .	45
1.4	Les données et leur traitement . . . . .	47
1.4.1	Les données de télédétection . . . . .	47
1.4.1.1	Les images satellites optiques . . . . .	47
1.4.1.1.1	Description . . . . .	47
1.4.1.1.2	Les pré-traitements . . . . .	47
1.4.1.1.3	Les traitements . . . . .	49
1.4.1.1.3.1	Calcul du NDVI . . . . .	49
1.4.1.1.3.2	L'estimation des variables biophysiques : utilisation du modèle couplé PROSPECT+SAIL (PROSAIL) . . . . .	49
1.4.1.2	Les images satellitaires radars . . . . .	51
1.4.1.2.1	Description . . . . .	51
1.4.1.2.2	Les prétraitements et l'extraction des paramètres radars . . . . .	51
1.4.1.3	Structuration des paramètres issus des données de télédétection du pixel à la parcelle . . . . .	52
1.4.1.4	Classification des données . . . . .	53
1.4.1.4.1	Les méthodes utilisées . . . . .	53
1.4.1.4.1.1	La méthode des $k$ plus proches voisins - KNN . . . . .	53
1.4.1.4.1.2	La méthode des séparateurs à vastes marges - SVM . . . . .	54
1.4.1.4.2	La validation des classifications . . . . .	55
1.4.2	Les observations et mesures terrain . . . . .	56
1.4.2.1	Les relevés d'occupation et d'utilisation des sols . . . . .	56
1.4.2.2	Les mesures spectrales . . . . .	56
1.4.2.2.1	Description . . . . .	56
1.4.2.2.2	Pré-traitements . . . . .	57
1.4.2.3	Les photographies hémisphériques . . . . .	58
1.4.2.3.1	Description . . . . .	60
1.4.2.3.2	Pré-traitements . . . . .	60
1.4.2.4	Les enquêtes . . . . .	61
1.4.2.5	Les relevés de biomasse . . . . .	61
	Synthèse et conclusion du premier chapitre . . . . .	63

<b>2 Du terrain à l'image : Quels paramètres dérivés des séries temporelles d'images de télédétection optiques sont les plus adaptés à l'étude des prairies ?</b>	<b>65</b>
Introduction . . . . .	67
2.1 Évaluation de paramètres dérivés d'une série temporelle optique à haute résolution spatiale pour estimer la biomasse des prairies . . . . .	69
2.1.1 Introduction . . . . .	71
2.1.2 Méthodologie . . . . .	71
2.1.2.1 Les données . . . . .	71
2.1.2.2 Traitement statistique des données . . . . .	72
2.1.2.3 Calcul de la quantité d'herbe disponible . . . . .	73
2.1.3 Résultats et discussion . . . . .	73
2.1.3.1 Comparaison des paramètres dérivés des images de télédétection et des relevés <i>in situ</i> . . . . .	73
2.1.3.2 Validation du modèle de régression . . . . .	75
2.1.3.3 Application : estimation du stock d'herbe à l'échelle d'une exploitation agricole . . . . .	75
2.1.4 Conclusion . . . . .	76
2.2 Évaluation de paramètres dérivés d'une série temporelle optique à haute résolution spatiale pour discriminer des pratiques agricoles sur des prairies . . . . .	77
2.2.1 Introduction . . . . .	79
2.2.2 Méthodologie . . . . .	79
2.2.2.1 Les données . . . . .	79
2.2.2.2 Mesure de la dissimilarité . . . . .	80
2.2.2.3 Classification des données . . . . .	82
2.2.3 Résultats et discussion . . . . .	82
2.2.3.1 Analyse des données . . . . .	82
2.2.3.1.1 Les mesures spectrales et les NDVI qui en sont dérivés . . . . .	82
2.2.3.1.2 LAI et fCOVER estimés à partir des photographies hémisphériques . . . . .	85
2.2.3.1.3 NDVI, LAI et fCOVER dérivés des images satellites . . . . .	86
2.2.3.2 Analyse de la dissimilarité . . . . .	87
2.2.3.3 Comparaison des paramètres dérivés des données observées <i>in situ</i> et des données de télédétection . . . . .	87
2.2.3.3.1 Pour le suivi du couvert végétal . . . . .	87
2.2.3.3.2 Pour l'identification des pratiques agricoles . . . . .	89
2.2.4 Conclusion . . . . .	94
Synthèse et conclusion du second chapitre . . . . .	95
<b>3 Exploitation de séries temporelles d'images satellites à haute résolution spatiale pour l'identification des prairies</b>	<b>97</b>
Introduction . . . . .	99
3.1 Analyse de séries temporelles d'images optiques à haute résolution spatiale pour l'identification des prairies . . . . .	101
3.1.1 Introduction . . . . .	103
3.1.2 Méthodologie . . . . .	103
3.1.3 Résultats . . . . .	104
3.1.3.1 Analyse des résultats de classification des séries temporelles . . . . .	104
3.1.3.2 Quelles séries temporelles pour l'identification des prairies ? . . . . .	107
3.1.3.2.1 Analyse des dates clés pour discriminer les prairies des cultures	107

3.1.3.2.2	Analyse du nombre d'images nécessaire pour discriminer les prairies des cultures . . . . .	109
3.1.4	Conclusion . . . . .	110
3.2	L'apport de séries temporelles d'images radars pour l'identification des prairies . . . . .	111
3.2.1	Classification d'une série temporelle d'images optiques SPOT 5 et Landsat et d'une série temporelle d'images Radarsat-2 en mode « Quad-pol » . . . . .	113
3.2.1.1	Introduction . . . . .	115
3.2.1.2	Méthodologie . . . . .	115
3.2.1.2.1	Les données . . . . .	115
3.2.1.2.2	Analyse statistique . . . . .	116
3.2.1.2.3	Classification . . . . .	117
3.2.1.3	Résultats . . . . .	117
3.2.1.3.1	Évaluation de la relation entre les coefficients de rétrodiffusion extraits des données radars et le LAI dérivé des données optiques . . . . .	117
3.2.1.3.2	Analyse de l'évolution temporelle de paramètres utilisés pour l'identification des prairies . . . . .	119
3.2.1.3.2.1	Les paramètres LAI et HH/VV extraits des données optiques et radars . . . . .	119
3.2.1.3.2.2	Paramètres polarimétriques entropie et alpha issus de la décomposition de Cloude-Pottier et extraits des données radars . . . . .	121
3.2.1.3.2.3	Paramètres polarimétriques issus de la décomposition de Freeman-Durden et extraits des données radars . . . . .	122
3.2.1.3.3	Analyse de la séparabilité entre les paramètres radars . . . . .	123
3.2.1.3.4	Classification . . . . .	124
3.2.1.4	Conclusion . . . . .	127
3.2.2	Classification d'une série temporelle d'images optiques SPOT 4 et d'une série temporelle d'images Radarsat-2 en mode « Ultra-fin » . . . . .	129
3.2.2.1	Introduction . . . . .	131
3.2.2.2	Méthodologie . . . . .	131
3.2.2.2.1	Les données . . . . .	131
3.2.2.2.2	Classification . . . . .	132
3.2.2.3	Résultats . . . . .	132
3.2.2.3.1	Évaluation de la relation entre le coefficient de rétrodiffusion VV dérivé des données Radarsat-2 et le LAI dérivé des données optiques SPOT . . . . .	132
3.2.2.3.2	Analyse de l'évolution temporelle du LAI et du coefficient de rétrodiffusion VV . . . . .	134
3.2.2.3.3	Analyse de la précision des classifications . . . . .	135
3.2.2.4	Conclusion . . . . .	136
	Synthèse et conclusion du troisième chapitre . . . . .	137
<b>4</b>	<b>Exploitation de séries temporelles d'images satellites à haute résolution spatiale pour l'identification des modes de gestion des prairies</b> . . . . .	<b>139</b>
	Introduction . . . . .	141
4.1	Comparaison de méthodes de classification pour identifier les modes de gestion des prairies . . . . .	143
4.1.1	Introduction . . . . .	145

4.1.2	Méthodologie . . . . .	145
4.1.2.1	Les données . . . . .	145
4.1.2.2	Classification de séries complexes basée sur des critères de déformation temporelle . . . . .	146
4.1.3	Résultats . . . . .	149
4.1.3.1	Analyse de l'évolution temporelle du LAI . . . . .	149
4.1.3.1.1	Données simulées . . . . .	149
4.1.3.1.2	Données réelles . . . . .	150
4.1.3.2	Performances des méthodes de classification des séries temporelles . . . . .	151
4.1.3.2.1	Résultats sur des données simulées . . . . .	151
4.1.3.2.2	Résultats sur des données réelles . . . . .	152
4.1.4	Conclusion . . . . .	153
4.2	Comparaison inter-annuelle de séries temporelles d'images optiques et/ou radars pour identifier les modes de gestion des prairies . . . . .	155
4.2.1	Introduction . . . . .	157
4.2.2	Méthodologie . . . . .	157
4.2.2.1	Les données . . . . .	157
4.2.2.2	Classification des séries temporelles . . . . .	158
4.2.3	Résultats . . . . .	158
4.2.3.1	Analyse de la séparabilité . . . . .	158
4.2.3.1.1	Séparabilité avec la série d'images acquise en 2010 . . . . .	158
4.2.3.1.2	Séparabilité avec la série d'images acquise en 2011 . . . . .	161
4.2.3.2	Classification des séries optiques et radars . . . . .	162
4.2.4	Conclusion . . . . .	164
	Synthèse et conclusion du quatrième chapitre . . . . .	165
	<b>Conclusion Générale</b> . . . . .	<b>167</b>
	<b>Bibliographie</b> . . . . .	<b>171</b>
	<b>A Annexe 1</b> . . . . .	<b>191</b>
	<b>B Annexe 2</b> . . . . .	<b>209</b>
	<b>C Annexe 3</b> . . . . .	<b>231</b>





---

## Exploitation de séries temporelles d'images satellites à haute résolution spatiale pour le suivi des prairies en milieu agricole

---

**Résumé :** En milieu agricole, on observe depuis plusieurs décennies une régression des prairies ainsi qu'une évolution de leur mode de gestion liées à l'intensification de l'agriculture. Face aux enjeux que ces changements impliquent tant sur le plan environnemental qu'économique, l'estimation de la place des prairies dans les systèmes de production et la détermination des pratiques agricoles qui leur sont associées sont stratégiques. Avec l'arrivée de nouveaux capteurs de télédétection à Haute Résolution Spatiale (HRS) caractérisés par une résolution temporelle élevée, il est désormais possible d'envisager l'étude des couverts prairiaux à une échelle fine et à partir d'observations régulières dans le temps. L'objectif de cette thèse est d'identifier les couverts prairiaux à l'échelle des territoires agricoles et de déterminer leurs modes de gestion à partir de paramètres dérivés de séries temporelles d'images de télédétection à HRS. Pour cela, plusieurs séries intra-annuelles d'images à haute résolution spatiale optiques et radars ont été constituées afin de recenser les prairies et d'identifier trois de leurs modes de gestion : le pâturage, la fauche et l'exploitation mixte, sur un bassin versant dont le système d'exploitation dominant est l'élevage laitier. Les résultats obtenus à partir du traitement et de l'analyse des séries temporelles optiques ont permis de montrer qu'il est possible d'estimer avec une bonne précision la biomasse des prairies, de les identifier et de les caractériser. Ils mettent aussi en évidence le fait que les images radars améliorent l'identification des prairies sans pouvoir discriminer leurs modes de gestion, l'utilisation combinée des deux types d'images augmentant encore le taux d'identification des prairies. Par ailleurs, les résultats montrent que les méthodes de classification s'appuyant sur des critères de comparaison adaptés aux séries temporelles (distances élastiques) produisent des résultats nettement plus satisfaisants pour discriminer les modes de gestion des prairies que les méthodes de classification standards.

**Mots clés :** Agriculture, Prairies, Modes de gestion, Télédétection, Images optiques, Images radars, LAI, Profils temporels, Classifications

---

## Use of time-series of high spatial resolution satellite images for grassland monitoring in agricultural areas

---

**Abstract:** In agricultural areas, we observed a decrease of grasslands and change in their management in the last half-century, which are commonly associated with agriculture intensification. These changes have affected environmental and economic systems. In this context, the evaluation of grassland status and grassland management in farming systems is a key-issue for sustainable agriculture. With the arrival of new Earth observation sensors with high spatial and temporal resolutions, it is now possible to study grasslands at fine scale using regular observations over time. The objective of this thesis is to identify grasslands and their management practices using parameters derived from time-series of high spatial resolution (HSR) remote sensing data. For that purpose, several intra-annual time series of HSR optical and Synthetic Aperture Radar (SAR) satellite images were acquired in order to identify grasslands and three of their management practices: grazing, mowing and mixed management, on a catchment area mainly oriented towards cattle production. Results obtained from the processing and analysis of the optical time series have shown that it is possible to estimate with good accuracy grassland biomass, to identify and to characterize them. They also highlighted that radar images improve grassland identification without being able to distinguish management practices, the combined use of the two types of images further increasing grassland identification. Furthermore, results showed that the classification methods based on comparison criteria adapted to time series (warping criteria) increase significantly results for discriminating grassland management practices compared to standard classification methods.

**Keywords:** Agriculture, Grassland, Management practices, Remote sensing, Optical images, SAR images, LAI, Temporal profiles, Classifications

Laboratoire LETG Rennes COSTEL, UMR 6554 CNRS OSU  
Université de Rennes 2,  
Place du Recteur Henri Le Moal, CS 24307,  
35043 RENNES cedex, France

