



# Thèse de doctorat

présentée pour obtenir le grade de docteur  
de l'UNIVERSITÉ PARIS-DESCARTES

École Doctorale EDITE

Spécialité : Informatique - Sciences de l'Information  
Géographique

Adrien GRESSIN

**Mise à jour d'une base de données  
d'occupation du sol à grande échelle  
en milieux naturels  
à partir d'une image satellite THR**

Version provisoire destinée aux rapporteurs  
Pour une soutenance le 12/12/2014,  
devant le jury composé de :

Jordi INGLADA	Rapporteur
Sébastien LEFEVRE	Rapporteur
Jocelyn CHANUSSOT	Examinateur
Devis TUIA	Examinateur
Florence TUPIN	Examinatrice
Nicolas PAPARODITIS	Directeur
Nicole VINCENT	Directrice
Clément MALLET	Encadrant





Cette thèse s'est déroulée au laboratoire MATIS (Méthodes d'Analyses pour le Traitement d'Images et la Stéréorestitution) du Service de la Recherche de l'Institut National de l'Information Géographique et Forestière (IGN) et au laboratoire LIPADE (Laboratoire d'Informatique Paris DEscartes) de l'Université Paris-Descartes.

Laboratoire MATIS  
Service de la Recherche en Sciences de l'Information Géographique  
Institut National de l'Information Géographique et Forestière  
73 avenue de Paris  
94165 Saint-Mandé cedex FRANCE  
Téléphone : 01 43 98 80 00

Laboratoire LIPADE  
Université Paris Descartes  
45 rue des Saints Pères  
75270 Paris Cedex 06 FRANCE  
Téléphone : 01 83 94 57 41

Référence BibTeX :

```
@PHDTHESIS{Gressin2014,  
  author = {Gressin, A.},  
  title = {Mise \à jour d'une base de donn\ees  
d'occupation du sol \à grande \echelle en milieux naturels  
\à partir d'une image satellite THR},  
  school = {Universit\e {P}aris-{D}escartes},  
  year = {2014}  
}
```



# Résumé

---

Les bases de données (BDs) d'occupation du sol (OCS) sont d'une grande utilité, par exemple pour le suivi des ressources naturelles, de l'aménagement du territoire et le pilotage des politiques publiques. Afin d'améliorer ce suivi, les utilisateurs recherchent des niveaux de détails tant géométriques que sémantiques très fins. Ainsi, une telle BD d'occupation du sol à grande échelle (OCS-GE) est en cours de constitution à l'Institut National de l'Information Géographique et Forestière (IGN). Cependant, pour répondre aux besoins des utilisateurs, cette BD doit être mise à jour le plus régulièrement possible, avec une notion de millésime. Ainsi, des méthodes automatiques de mise à jour doivent être mises en place, afin de traiter rapidement des zones étendues. Par ailleurs, les satellites d'observation de la terre ont fait leurs preuves dans l'aide à la constitution de BD d'OCS à des échelles comparables à celle de Corine Land Cover (CLC). Avec l'arrivée de nouveaux capteurs très haute résolution (THR), comme celle du satellite Pléiades, la question de la pertinence de ces images pour la mise à jour de BD d'OCS-GE se pose naturellement. Ainsi, l'objet de cette thèse est de développer une méthode automatique de mise à jour de BDs d'OCS-GE, à partir d'une image satellite THR monoscopique (afin de réduire les coûts d'acquisition), tout en garantissant la robustesse des changements détectés.

Le cœur de la méthode est un algorithme d'apprentissage supervisés multi-niveaux appelé Multi Level, Multi Object Learning (MLMOL), qui permet de prendre en compte au mieux les apparences, éventuellement multiples, de chaque thème de la BD. Cet algorithme, complètement indépendant du choix du classifieur et des attributs extraits de l'image, peut être appliqué sur des jeux de données très variés. De plus, la multiplication de classifications permet d'améliorer la robustesse de la méthode, en particulier sur des thèmes ayant des apparences multiples (*e.g.*, champs labourés ou non, bâtiments de type maison ou hangar industriel, ...).

De plus, l'algorithme d'apprentissage est intégré dans une chaîne de traitements (L<sup>PN</sup>) capable, d'une part de s'adapter automatiquement aux différents thèmes de la BD pouvant exister et, d'autre part, d'être robuste à l'existence de thèmes in-homogènes. L<sup>PN</sup> repose sur l'extraction d'un très grand nombre d'attributs spatiaux et spectraux issus de la littérature, délivrant des informations spectrales, mais également morphologiques et de texture. Ce très grand nombre d'attributs, couplé à une sélection d'attributs par thème, permet d'obtenir des

classifications de qualité sur des thèmes très variés. La chaîne de traitements fournit une carte de probabilité de changements permettant de garder une mesure de la confiance dans le résultat obtenu et, ainsi, de diriger le travail d'un opérateur, soit sur les zones de changements certains, soit sur les zones d'incertitude. La méthode est validée sur différents jeux de données simulées ou générées à partir d'images satellite THR.

Par suite, la méthode est appliquée avec succès à une image Pléiades, sur une zone à proximité de Tarbes (65) couverte par la BD OCS-GE constituée par IGN. Les résultats obtenus montrent l'apport des images Pléiades tant en terme de résolution sub-métrique que de dynamique spectrale. En effet, ces images permettent d'avoir des résultats de classification corrects, même sur des thèmes comme les routes et les bâtiments qui nécessitent habituellement des méthodes spécifiques, grâce aux attributs de texture et de forme (profil morphologique, SFS, ...). D'autre part, la méthode proposée permet de fournir des indicateurs pertinents de changements sur la zone.

Nous montrons par ailleurs que notre méthode peut fournir une aide précieuse à la constitution de BD d'OCS issues de la fusion de différentes BDs. En effet, notre méthode a la capacité de prise de décisions lorsque la fusion de BDs génère des zones de recouvrement, phénomène courant notamment lorsque les données proviennent de différentes sources, avec leur propre spécification. De plus, notre méthode permet également de compléter d'éventuels lacunes dans la zone de couverture de la BD générée, mais aussi d'étendre cette couverture sur l'emprise d'une image couvrant une étendue plus large.

Enfin, la chaîne de traitements LPN est appliquée à différents jeux de données de télédétection afin de valider sa polyvalence et de juger de la pertinence de ces données. Les résultats montrent sa capacité d'adaptation aux données de différentes résolutions utilisées (Pléiades à 0,5 m, SPOT 6 à 1,5 m et RapidEye à 5 m), ainsi que sa capacité à utiliser les points forts des différents capteurs, comme par exemple le canal red-edge de RapidEye pour la discrimination du thème forêts, le bon compromis de résolution que fournit SPOT 6 pour le thème *zones bâties* et l'apport de la THR de Pléiades pour discriminer des thèmes précis comme les routes ou les haies.

**Mots Clés :** *Télédétection, Classification, Apprentissage, Mise à jour de BD, Occupation du sol, Images satellite THR, Pléiades.*

# Abstract

---

Land-Cover geospatial databases (LC-BDs) are mandatory inputs for various purposes such as for natural resources monitoring land planning, and public policies management. To improve this monitoring, users look for both better geometric, and better semantic levels of detail. To fulfill such requirements, a large-scale LC-DB is being established at the French National Mapping Agency (IGN). However, to meet the users needs, this DB must be updated as regularly as possible while keeping the initial accuracies. Consequently, automatic updating methods should be set up in order to allow such large-scale computation. Furthermore, Earth observation satellites have been successfully used to the constitution of LC-DB at various scales such as Corine Land Cover (CLC). Nowadays, very high resolution (VHR) sensors, such as Pléiades satellite, allow to product large-scale LC-DB. Consequently, the purpose of this thesis is to propose an automatic updating method of such large-scale LC-DB from VHR monoscopic satellite image (to limit acquisition costs) while ensuring the robustness of the detected changes.

Our proposed method is based on a multilevel supervised learning algorithm MLMOL, which allows to best take into account the possibly multiple appearances of each DB classes. This algorithm can be applied to various images and DB data sets, independently of the classifier, and the attributes extracted from the input image. Moreover, the classifications stacking improves the robustness of the method, especially on classes having multiple appearances (*e.g.*, plowed or not plowed fields, stand-alone houses or industrial warehouse buildings, ...).

In addition, the learning algorithm is integrated into a processing chain ( $\mathbb{L}\mathbb{P}\mathbb{N}$ ) allowing, first to automatically fit to the different existing DB themes and, secondly, to be robust to in-homogeneous areas.  $\mathbb{L}\mathbb{P}\mathbb{N}$  is based on the extraction of a large number of attributes (from the remote sensing and the computer vision literature), providing spectral, morphological, and textural information. These attributes, coupled with an attributes selection for each DB classes, provides high quality classifications on a large range of classes. Furthermore, the workflow provides a probability change map, allowing to keep a confidence measure, and so to point a manual operator either on changes areas, or on areas of uncertainty. The method is assessed on several simulated or generated data sets derived from VHR satellite images.

As a result, the method is successfully applied to a Pleiades image on an area

near Tarbes (southern France) covered by the IGN large-scale LC-DB. Results show the contribution of Pleiades images (in terms of sub-meter resolution and spectral dynamics). Indeed, thanks to the texture and shape attributes (morphological profiles, SFS, . . .), VHR satellite images give good classification results, even on classes such as roads, and buildings that usually require specific methods. Moreover, the proposed method provides relevant change indicators in the area.

In addition, our method provides a significant support for the creation of LC-DB obtain by merging several existing DBs. Indeed, our method allows to take a decision when the fusion of initials DBs generates overlapping areas, particularly when such DBs come from different sources with their own specification. In addition, our method allows to fill potential gaps in the coverage of such generating DB, but also to extend the data to the coverage of a larger image.

Finally, the proposed workflow is applied to different remote sensing data sets in order to assess its versatility and the relevance of such data. Results show that our method is able to deal with such different spatial resolutions data sets (Pléiades at 0.5 m, SPOT 6 at 1.5 m and RapidEye at 5 m), and to take into account the strengths of each sensor, *e.g.*, the RapidEye red-edge channel for discrimination theme forest, the good balance of the SPOT 6 resolution for *built-up areas* classes and the capability of VHR of Pléiades images to discriminate objects of small spatial extent such as roads or hedge.

**Keywords :** *Remote sensing, Classification, Learning, DB updating, Land Cover, VHR satellite images, Pléiades.*

# Table des matières

---

Résumé	iii
Abstract	v
Table des matières	x
<b>I Introduction</b>	<b>1</b>
<b>1 Contexte</b>	<b>3</b>
1.1 Les bases de données d’occupation du sol . . . . .	4
1.1.1 Différentes nomenclatures pour différents usages . . . . .	5
1.1.2 Constitution de l’OCS-GE à l’IGN . . . . .	10
1.1.3 Besoin de complétion et de mise-à-jour . . . . .	11
1.2 Évolution des données satellite et nouveaux capteurs très haute résolution . . . . .	12
1.2.1 Évolution des capteurs optiques spatiaux . . . . .	12
1.2.2 Les capteurs très haute résolution . . . . .	13
1.3 Problématique et approche proposée . . . . .	16
1.3.1 Problématique . . . . .	16
1.3.2 Stratégie générale . . . . .	17
1.3.3 Organisation du manuscrit . . . . .	17
<b>II État de l’art</b>	<b>19</b>
<b>2 Méthodes de détection de changements et de mise à jour de bases de données en télédétection</b>	<b>21</b>
2.1 Entre deux ou plusieurs images . . . . .	23
2.1.1 Couple d’images . . . . .	23
2.1.2 Série d’images . . . . .	24
2.2 Entre une base de données et une (ou plusieurs) image(s) . . . . .	25
2.3 Conclusion . . . . .	26
<b>3 Quels attributs pour la classification d’images à très haute ré- solution spatiale ?</b>	<b>29</b>
3.1 Attributs spectraux . . . . .	30

3.1.1	Thématiques . . . . .	31
3.1.2	Espaces colorimétriques . . . . .	32
3.2	Attributs de texture . . . . .	34
3.2.1	Analyse statistique . . . . .	35
3.2.2	Analyse fréquentielle . . . . .	41
3.3	Attributs géométriques et notion d'objet . . . . .	47
3.3.1	Attributs de forme . . . . .	47
3.3.2	Attributs morphologiques . . . . .	47
3.3.3	Notion d'objet (ou région) . . . . .	49
3.4	Conclusion . . . . .	51
<b>4</b>	<b>Réduction de dimension et sélection d'attributs</b>	<b>53</b>
4.1	Réduction de dimension . . . . .	54
4.1.1	Méthodes linéaires . . . . .	54
4.1.2	Méthodes non-linéaires . . . . .	55
4.2	Sélection d'attributs . . . . .	56
4.2.1	Méthodes d'exploration . . . . .	57
4.2.2	Méthodes d'évaluation . . . . .	58
4.2.3	Sélection d'attributs en télédétection . . . . .	58
4.3	Conclusion . . . . .	59
<b>5</b>	<b>Méthodes de classification et leurs utilisations en télédétection</b>	<b>61</b>
5.1	Classification non-supervisée . . . . .	62
5.2	Classification supervisée . . . . .	64
5.2.1	Choix d'un ensemble d'apprentissage . . . . .	64
5.2.2	Algorithmes de classification supervisée . . . . .	65
5.3	Ensemble et fusion de classifieurs . . . . .	71
5.3.1	Ensemble de classifieurs . . . . .	71
5.3.2	Fusion de classifieurs . . . . .	72
5.4	Évaluation d'une classification . . . . .	73
5.5	Conclusion . . . . .	75
<b>III</b>	<b>Méthodologie de mise à jour de BD d'OCS</b>	<b>77</b>
<b>6</b>	<b>Méthodologie générique de mise à jour de bases de données géographiques (MLMOL)</b>	<b>79</b>
6.1	Notations . . . . .	80
6.1.1	Structure des bases de données géographiques . . . . .	80
6.1.2	Lien entre base de données et image . . . . .	82
6.1.3	Classification supervisée binaire . . . . .	83
6.2	Inspection hiérarchique de la base de données géographique . . . . .	84
6.2.1	Niveau objet . . . . .	84
6.2.2	Niveau classe . . . . .	87
6.2.3	Niveau base de données . . . . .	87
6.3	Validation théorique de la méthode . . . . .	89
6.3.1	Présentation des données simulées . . . . .	89
6.3.2	Expérimentations . . . . .	90
6.4	Conclusion . . . . .	93



<b>7</b>	<b>Intégration de la méthode MLMOL dans la chaîne de traitements <math>\mathbb{L}\mathbb{P}\mathbb{N}</math></b>	<b>97</b>
7.1	Intégration de MLMOL dans la chaîne $\mathbb{L}\mathbb{P}\mathbb{N}$ . . . . .	98
7.1.1	Extraction d'attributs . . . . .	98
7.1.2	Sélection d'attributs . . . . .	100
7.1.3	Choix du classifieur . . . . .	103
7.1.4	Choix de la méthode de fusion . . . . .	104
7.1.5	Premiers pas vers un passage à l'échelle . . . . .	106
7.2	Expériences sur un jeu de données généré . . . . .	108
7.2.1	Description du jeu de données . . . . .	108
7.2.2	Attributs et classification . . . . .	108
7.2.3	Complétion . . . . .	109
7.2.4	Mise à jour . . . . .	109
7.2.5	Complétion et mise à jour conjointes . . . . .	110
7.3	Conclusion . . . . .	110
<b>IV</b>	<b>Application à la mise à jour de données OCS</b>	<b>113</b>
<b>8</b>	<b>Mise à jour de BD OCS à partir d'une image Pléiades</b>	<b>115</b>
8.1	Jeu de données . . . . .	116
8.1.1	Image satellite . . . . .	116
8.1.2	Occupation du sol . . . . .	116
8.2	Résultats sur OCS simplifiée . . . . .	120
8.3	Résultats sur OCS-GE . . . . .	121
8.3.1	Étude chiffrée des classifications . . . . .	123
8.3.2	Étude visuelle . . . . .	124
8.3.3	Résultats supplémentaires . . . . .	129
8.4	Étude des temps de traitements . . . . .	135
8.5	Conclusion . . . . .	136
<b>9</b>	<b>Application à différents jeux de données</b>	<b>137</b>
9.1	Différentes résolutions spatiales . . . . .	138
9.1.1	Présentation des données . . . . .	138
9.1.2	Résultats . . . . .	140
9.1.3	Étude visuelle . . . . .	141
9.2	Données multi-temporelles . . . . .	143
9.2.1	Présentation des données . . . . .	143
9.2.2	Méthodes utilisées . . . . .	143
9.2.3	Résultats . . . . .	148
9.2.4	Analyse visuelle . . . . .	148
9.3	Conclusion . . . . .	150
<b>V</b>	<b>Conclusion et perspectives</b>	<b>153</b>
<b>10</b>	<b>Conclusion et perspectives</b>	<b>155</b>
10.1	Conclusion . . . . .	156

10.2 Contributions et limitations . . . . .	157
10.3 Perspectives d'améliorations et d'applications . . . . .	158
10.3.1 Améliorations des classifications . . . . .	159
10.3.2 Passage à l'échelle . . . . .	160
10.3.3 Applications envisagées . . . . .	162
<b>Bibliographie</b>	<b>163</b>
<b>Termes et abréviations</b>	<b>187</b>
<b>A Données et résultats supplémentaires</b>	<b>193</b>
<b>B Publications</b>	<b>201</b>

# Table des figures

---

1.1	Occupation du sol : Différentes échelles . . . . .	5
1.2	Corine Land Cover 2006 . . . . .	7
1.3	Occupation du sol Languedoc-Roussillon . . . . .	8
1.4	Occupation du sol PACA et IdF . . . . .	9
1.5	Occupation du sol IGN . . . . .	11
1.6	Évolution des images satellite SPOT et Pléiades . . . . .	15
1.7	Schéma général de la chaîne de traitements LPN . . . . .	18
3.1	Représentation de la réponse spectrale de différents types de cou- vertures du sol dans le domaine visible et proche-infrarouge. . . . .	31
3.2	Extrait d'une image Pléiades . . . . .	33
3.3	Espace colorimétrique TSL (Teinte Saturation Lumière). . . . .	33
3.4	Extrait de l'image Pléiades en TLS . . . . .	34
3.5	Attributs de texture : notion d'échelle et d'isotropie . . . . .	35
3.6	Attributs statistiques extraits d'une image Pléiades . . . . .	37
3.7	Attributs colorimétriques extraits d'une image Pléiades . . . . .	38
3.8	Attributs Haralick extraits d'une image Pléiades . . . . .	40
3.9	Attributs de complexité extraits d'une image Pléiades . . . . .	42
3.10	Transformée de Fourier appliquée à une image Pléiades . . . . .	43
3.11	Filtres de Haar appliqués à une image Pléiades . . . . .	44
3.12	Ondelette de Gabor . . . . .	45
3.13	Attributs Gabor extraits d'une image Pléiades . . . . .	45
3.14	Autres attributs de texture extraits d'une image Pléiades . . . . .	46
3.15	Attributs SFS extraits d'une image Pléiades . . . . .	48
3.16	Profils d'attributs morphologiques extraits d'une image Pléiades . . . . .	49
3.17	Segmentations d'une image Pléiades . . . . .	50
4.1	Analyse en Composante Principale . . . . .	55

4.2	Réduction de dimension . . . . .	56
5.1	Résultats des k-moyennes . . . . .	63
5.2	Séparateur à Vaste Marge . . . . .	67
5.3	Utilisation d'un noyau dans les SVMs . . . . .	68
5.4	Schéma des Forêts Aléatoires . . . . .	70
5.5	Matrice de confusion pour l'évaluation d'une classification binaire. . . . .	74
5.6	Interprétation d'une courbe ROC . . . . .	75
6.1	Schéma général de la méthode de mise à jour LPN . . . . .	81
6.2	Représentation d'une base de données géographique . . . . .	82
6.3	Schéma détaillé de la méthode MLMOL . . . . .	85
6.4	Présentation des données simulées . . . . .	90
6.5	Résultat sur les données simulées . . . . .	92
6.6	Résultats sur les données simulées . . . . .	94
7.1	Schéma des adaptations apportées à la méthode générale. . . . .	99
7.2	Importance des attributs par classe . . . . .	102
7.3	Comparaison des différents classifieurs. . . . .	105
7.4	Comparaison des différentes méthodes de fusion . . . . .	106
7.5	Présentation du jeu de données générées . . . . .	108
7.6	Données générées : résultats pour différentes couvertures . . . . .	109
7.7	Données générées : résultats pour différents changements . . . . .	110
7.8	Données générées : résultats chiffrés pour différents changements et différentes couvertures . . . . .	111
7.9	Données générées : résultats en fonction de la couverture et du changement dans la BD initiale . . . . .	111
8.1	Image Pléiades : Tarbes, septembre 2013 . . . . .	117
8.2	BD OCS-GE produite par l'IGN sur Tarbes . . . . .	119
8.3	Résultats sur BD simplifiée . . . . .	122
8.4	Résultats détaillés de classification (Zone 1) . . . . .	126
8.5	Résultats détaillés de classification (Zone 2) . . . . .	127
8.6	Résultats détaillés de classification (Zone 3) . . . . .	128
8.7	Résultats globaux de classification . . . . .	129
8.8	Résultats globaux de classification (5 thèmes) . . . . .	130
8.9	Carte de changements . . . . .	131
8.10	Carte de changements (5 thèmes) . . . . .	132
8.11	Détails de la carte de changements . . . . .	133

8.12	Détails résultats (superpositions) . . . . .	134
8.13	Détails résultats (complétion) . . . . .	135
9.1	Données Pléiades, SPOT 6 et RapidEye sur Tarbes . . . . .	139
9.2	RapidEye (Red-Edge) . . . . .	140
9.3	Détails des classifications (1/2) . . . . .	144
9.4	Détails des classifications (2/2) . . . . .	145
9.5	Données RapidEye multi-dates . . . . .	146
9.6	Méthodes de fusion multi-dates . . . . .	147
9.7	Comparaison détaillée des différentes fusions . . . . .	151
A.1	Importance des attributs par classe pour les profils morphologiques (AP) . . . . .	196
A.2	Importance des attributs par classe pour les attributs colorimétrique (CD) . . . . .	197
A.3	Importance des attributs par classe pour les attributs de textures Haralick (HK) . . . . .	198
A.4	Importance des attributs par classe pour les attributs spectraux (SP) . . . . .	199



# Liste des tableaux

---

1.1	Évolution des satellites SPOT et Pléiades . . . . .	14
3.1	Les huit canaux d'Haralick existants. . . . .	39
7.1	Liste des attributs utilisés . . . . .	101
7.2	Nombre d'attributs uniques sélectionnés sur l'ensemble des thèmes par famille d'attributs. . . . .	103
7.3	Comparaison des différentes méthodes de fusion . . . . .	107
8.1	Détails de la BD OCS-GE sur Tarbes . . . . .	118
8.2	Légende des classes de la BD OCS-GE sur Tarbes . . . . .	118
8.3	Résultats chiffrés sur OCS-GE . . . . .	123
8.4	Résultats détaillés et chiffrés sur OCS-GE . . . . .	125
9.1	Comparaison différents capteurs . . . . .	140
9.2	Comparaison détaillée des différents capteurs . . . . .	142
9.3	Comparaison différentes fusions . . . . .	148
9.4	Comparaison détaillée des différentes fusions . . . . .	149
A.1	Nomenclature Corine Land Cover . . . . .	194
A.2	Nomenclature OCS-GE . . . . .	195






**Première partie**

**Introduction**



# Contexte

---



## Sommaire

---

<b>2.1</b>	<b>Entre deux ou plusieurs images . . . . .</b>	<b>23</b>
2.1.1	Couple d'images . . . . .	23
2.1.2	Série d'images . . . . .	24
<b>2.2</b>	<b>Entre une base de données et une (ou plusieurs) image(s) . . . . .</b>	<b>25</b>
<b>2.3</b>	<b>Conclusion . . . . .</b>	<b>26</b>

---



---

1. Source : <http://freegisdata.org/>

2. Source : <http://regard-sur-la-terre.over-blog.com>

## 1.1 Les bases de données d'occupation du sol

L'occupation du sol (OCS) est définie comme la description de la couverture physique, naturelle ou anthropologique, de la surface de la Terre. La notion d'occupation du sol (ou couverture du sol) doit être discernée de celle d'utilisation du sol. Cette dernière fait référence à l'usage d'un territoire, comme par exemple l'habitat, le commerce, ou encore l'industrie. Cependant l'utilisation du sol n'est pas directement visible par télédétection ou photo-interprétation et nécessite généralement des données annexes pour être cartographiées. D'autre part, ces deux notions sont très souvent mélangées dans les nomenclatures existantes, par exemple dans Corine Land Cover (CLC). Par la suite, nous nous intéresserons uniquement à l'occupation du sol, qui est la seule observable par télédétection.

Une description fine de l'occupation du sol est utile pour la compréhension des écosystèmes, des agrosystèmes et des territoires. Elle fournit également de précieux indicateurs pour la gestion des ressources naturelles et de l'aménagement du territoire [Balestrat, 2011], et permet ainsi un suivi précis de l'évolution des territoires et une évaluation des politiques publiques. On peut citer par exemple le suivi de l'étalement urbain (étalement spatial, densification, mutations urbaines), le suivi d'indicateurs environnementaux (zones humides, diversité des plantations forestières, ...).

Dans le domaine des politiques publiques françaises, un très grand nombre de documents d'urbanisme et de lois reposent sur une telle connaissance :

- La Loi du Grenelle 2<sup>3</sup> pour une gestion économe de l'espace avec un renforcement du rôle des documents d'urbanisme (12 juillet 2010) ;
- Les Schémas de Cohérence Territoriale (SCoTs) et les Plans Locaux d'Urbanisme (PLU) doivent fixer des objectifs chiffrés de limitation de la consommation d'espaces naturels, agricoles et forestiers ;
- La Loi de modernisation de l'agriculture et de la pêche<sup>4</sup> (27 juillet 2010) ;
- La Loi d'avenir pour l'agriculture, l'alimentation et la forêt<sup>5</sup> dont le but est la préservation des terres agricoles : réduire de moitié le rythme de consommation des surfaces agricoles d'ici 2020.

Toute description d'un territoire repose sur le choix d'une nomenclature dépendant grandement de l'application souhaitée. Ainsi, différentes nomenclatures sont présentées dans la sous-section 1.1.1. En particulier le choix de l'Institut National de l'Information Géographique et Forestière (IGN) et de ces partenaires pour une nomenclature nationale est détaillé. Puis, le processus de génération de cette base de données à partir de données existantes est décrit (sous-section 1.1.2). Enfin, le besoin des utilisateurs en données rapidement mises à jour et millésimées est analysé dans la sous-section 1.1.3.

---

3. <http://www.legifrance.gouv.fr/affichTexte.do?cidTexte=JORFTEXT000022470434>

4. <http://www.legifrance.gouv.fr/affichTexte.do?cidTexte=JORFTEXT000022521587>

5. <http://www.assemblee-nationale.fr/14/ta/ta0273.asp>

### 1.1.1 Différentes nomenclatures pour différents usages

La description de la surface terrestre en terme d'occupation nécessite au préalable la définition d'une nomenclature (en particulier des différents thèmes, ou classes, qui la composent) et d'un ensemble de règles géographiques, comme l'unité minimale de collecte (correspondant à la taille minimale des objets qui apparaîtront dans la base de données (BD)). Ainsi, de ces différents éléments dépendront la **précision géographique** et la **précision sémantique** de la BD produite (Figure 1.1).




FIGURE 1.1 – Deux nomenclatures différentes sur une même zone, extrait de la BD OCS de la région Provence-Alpes-Côte d'Azur, Marseille, Vieux-Port.

Bien que ces deux précisions soient différentes, elles sont souvent confondues. En effet, une nomenclature peu détaillée correspond, généralement, à une précision géométrique faible. Et la précision géométrique est souvent liée à la couverture de la BD : une BD couvrant une grande surface, continentale ou mondiale par exemple, aura une précision géométrique réduite, contrairement à une BD couvrant une surface plus réduite, telle que celle d'une commune ou d'un département.

Les nomenclatures existantes sont composées de plusieurs niveaux (nomenclatures hiérarchiques). Par exemple, une classe forêts de premier niveau, sera divisée en forêts de feuillus, forêts de conifère et forêts mixtes dans un second niveau. Les nomenclatures contiennent classiquement jusqu'à quatre niveaux de hiérarchie (Tableau A.2).

Dans cette partie, nous donnerons un aperçu de plusieurs initiatives de BD d'OCS, réparties en fonction de la zone géographique couverte (1.1.1, 1.1.1) ou de leur thématique particulière (1.1.1). Enfin, l'initiative de l'IGN et de ces partenaires pour une nomenclature nationale est détaillée (1.1.1).

#### Initiatives européennes

L'Agence Environnementale Européenne (EEA) et l'Union européenne ont lancé conjointement un programme de surveillance globale de l'environnement et de la sécurité Global Monitoring for Environment and Security (GMES) en 1997. Ce programme, maintenant appelé Copernicus, a pour double objectif de constituer une BD de gestion des territoires et de promouvoir son utilisation et

sa diffusion.

Le programme Copernicus est à l'origine de l'une des bases de données d'occupation du sol les plus connues : Corine Land Cover (CLC). La triple vocation de cette BD est de rassembler l'information relative à l'environnement sur certaines classes prioritaires, de coordonner les efforts de collecte des données et de garantir la cohérence et la compatibilité des données.

Couvrant l'ensemble du territoire européen et une partie des pays limitrophes (Figure 1.2), CLC a été construite autour d'une nomenclature hiérarchisée à 3 niveaux et 44 postes répartis selon 5 grands types d'occupation du territoire<sup>6</sup> : territoires artificialisés, territoires agricoles, forêts et milieux semi-naturels, zones humides et surfaces en eau. L'ensemble de la nomenclature est présentée dans le Tableau A.1. Comme précisé dans la section 1.1.1, cette nomenclature peut accueillir d'autres niveaux locaux plus fins. Par ailleurs, la nomenclature de CLC a la particularité de mêler des classes d'occupation du sol et des classes d'usage du sol, ce qui peut poser problème pour sa mise à jour par télédétection.

CLC a été produite en 1990 par photo-interprétation à partir d'ortho-images ; l'unité minimale de collecte est de 25 ha (avec une largeur supérieure à 100 m pour les objets allongés). Puis elle a été mise à jour en 2000 et 2006. La mise à jour est composée d'une nouvelle version de la BD, mais également d'une carte des changements entre cette nouvelle version et l'ancienne version. La carte des changements permet d'étudier facilement l'évolution des territoires.

De plus, l'EEA développe des services autour des domaines suivants : la terre, la mer, l'atmosphère, la sécurité, la gestion des urgences et l'adaptation au changement climatique. Dans le premier domaine, le service Geoland-2 propose cinq couches thématiques (HR Layers<sup>7</sup>) sur les zones imperméables, la forêt, les prairies, les zones humides et l'eau.

Enfin, EEA diffuse également l'Urban Atlas<sup>8</sup>, qui fournit une occupation du sol détaillée sur les zones urbaines. La première version date de 2006 et une mise à jour a été réalisée en 2012.

Par ailleurs, le projet Harmonised European Land Monitoring (HELM), auquel l'IGN participe, a pour vocation d'harmoniser au niveau européen les données en lien avec la surveillance des terres.

Dans le même domaine, on peut également évoquer la directive Infrastructure for Spatial Information in the European Community (INSPIRE)<sup>10</sup> qui a été créée par la Direction générale de l'environnement de la Commission européenne. Le but de cette dernière est d'établir une infrastructure de données géographiques européenne permettant l'interopérabilité entre les bases de données des différents

---

6. <http://www.statistiques.developpement-durable.gouv.fr/donnees-ligne/t/nomenclature.html>

7. <http://www/gmes-geoland.info/porjecct-documentation/product-service-specifications.html>

8. <http://www.eea.europa.eu/data-and-maps/data/urban-atlas>

10. <http://eur-lex.europa.eu/LexUriServ/LexUriServ.do?uri=OJ:L:2007:108:0001:0014:FR:PDF>

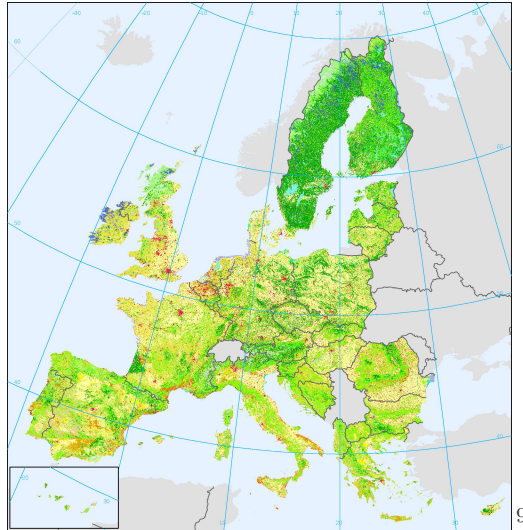


FIGURE 1.2 – Couverture Européenne de la base de données d’occupation du sol Corine Land Cover en 2006.

pays, afin de faciliter la diffusion et l’utilisation de l’information géographique. La directive INSPIRE s’intéresse en particulier aux données d’occupation du sol.

### Initiatives régionales / locales

Plusieurs initiatives régionales existent en France, nous détaillerons ici les initiatives des régions Languedoc-Roussillon, Provence-Alpes-Côte d’Azur et Île-de-France qui sont parmi les plus abouties.

En 1999 et en 2006, la région Languedoc-Roussillon, par l’intermédiaire du SIG L-R<sup>11</sup> a produit une BD d’OCS (Figure 1.3), dont la nomenclature est fondée sur la celle de CLC (*cf.* section 1.1.1), avec un certain nombre de changements pour s’adapter au mieux aux spécificités régionales et améliorer la précision géographique. Par exemple, la classe « bâti diffus » a été rajoutée, la classe « Plages, dunes et sable » a été modifiée pour intégrer le lit des fleuves et des rivières et la classe « Estuaires » a été supprimée. Cette BD a été produite à partir de BD existantes ( base de données Ortho-photographique de l’IGN (BD-Ortho), base de données Altimétrique de l’IGN (BD-Alti), CLC et GEOZOOM) et par photo-interprétation sur des images Landsat 7 à une résolution de 30 m. Par exemple, le « bâti diffus » a été obtenu par pointage manuel des bâtiments sur la BD-Ortho, puis par l’application d’un ensemble de règles géographiques. L’utilisation des ortho-images pose le problème du millésime des données. En effet, pour la BD de 2006, les ortho-images utilisées datent de 2003 à 2006, suivant les départements et ont une résolution de 0,5 m.

Dans la région Provence-Alpes-Côte d’Azur (PACA) (Figure 1.4a), le Centre

11. <http://siglr.org/>

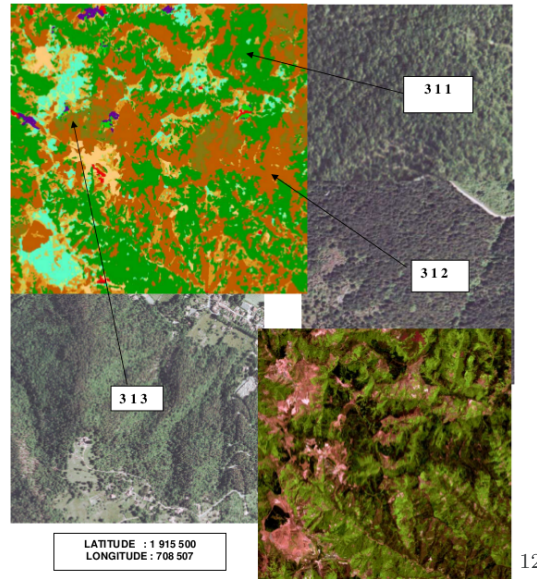


FIGURE 1.3 – Détails de 3 classes de forêts différentes dans la BD OCS de la région Languedoc-Roussillon, extrait du rapport du SIG L-R sur l’occupation du sol en Languedoc - Roussillon (1999 et 2006)

Régionale de l’Information Géographique (CRIGE)-PACA a réalisé une nomenclature, elle aussi fondée sur CLC. Elle est composée de 36 classes d’espaces emboîtées sur 3 niveaux. Certaines classes sont caractéristiques des spécificités de la région PACA, comme les classes : « Zones à forte densité de serres », « Oliveraies » et « Maquis et garrigues ». Ces données ont été produites à partir d’images satellites de 30m de résolution et dont l’unité minimale est de collecte de 2,5 ha pour les postes d’espaces naturels et agricoles.

De son côté, la région Île-de-France développe depuis 1982 une base de données d’occupation du sol sur l’ensemble de son territoire : le Mode d’Occupation du Sol (MOS)<sup>13</sup> (cf. Figure 1.4b). Cette BD comporte 8 mises à jour, dont la dernière date de 2012. Chaque mise à jour a été réalisée par photo-interprétation sur des ortho-images aériennes. La nomenclature comporte un total de 81 postes, mais trois variantes compatibles de 11, 24 et 47 postes existent également. Ainsi, la nomenclature peut être hiérarchisée en 4 niveaux.

### Initiatives thématiques

Face aux initiatives territoriales, il existe un certain nombre d’initiatives thématiques, dont le but n’est plus la description exhaustive d’un territoire donné, mais plutôt la description suivant un certain point de vue de ce territoire.

Par exemple, le Ministère de l’Écologie, du Développement Durable et de l’Énergie a lancé le projet Cartographie des habitats et végétations de France

13. <http://www.iau-idf.fr/cartes/mode-doccupation-du-sol-mos.html>



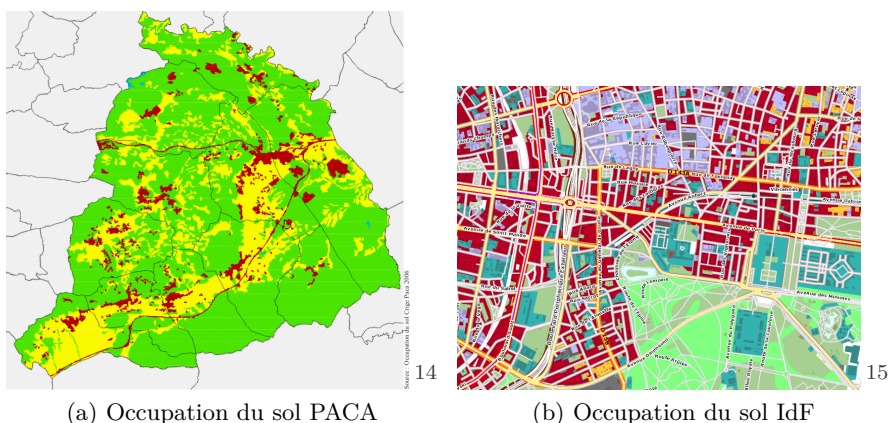


FIGURE 1.4 – Occupation du sol sur (a) le SCoT Coeur du Var en 2006 (selon les trois grands espaces d’occupation : naturels ■, agricoles ■ et artificialisés ■) et (b) la région Île-de-France en 2012 (Mode d’Occupation du Sol).

(Car Hab) au 1/25000, qui doit produire une cartographie des habitats par croisement de deux couches d’informations : le Fond Blanc (une carte physiologique des formations végétales) et un ensemble de variables écologiques. Dans ce projet, le Fond Blanc est une BD OCS thématique, qui aura donc une nomenclature adaptée à cette problématique. La génération de cette BD est essentiellement prévue par fusion de données existantes.

Par ailleurs, toujours dans le contexte de la préservation de l’environnement, le projet Artificialisation des sols, lancé par IGN et Institut National de Recherche en Sciences et Technologies pour l’Environnement et l’Agriculture (IRSTEA), permettra de suivre le rythme de consommation des espaces agricoles. Ce projet s’intéresse uniquement à la « tâche artificialisée », la nomenclature de la BD ne comporte donc qu’une seule classe. Le projet étant en cours de lancement à la date d’écriture de ce document, les détails des spécifications de cette BD ne sont pas encore connus. Cependant, cette BD devrait être générée à partir d’algorithmes de classification automatique appliqués sur des images aériennes ou satellite très haute résolution.

## Vers un référentiel national unique

Dans les parties précédentes, nous avons pu constater l’existence d’un grand nombre d’initiatives de BDs d’OCS couvrant partiellement ou totalement le territoire français. Dans ce contexte, l’IGN, en tant qu’opérateur national, a pour vocation la constitution d’un référentiel national unique et homogène sur l’ensemble du territoire. La définition de ce référentiel a été réalisée par concertation avec un grand nombre d’acteurs locaux, régionaux ou nationaux français. Ainsi, il est structuré afin de permettre un suivi précis de l’évolution de l’occupation du sol et doit répondre aux principes suivants : être compatible avec les couches

du Référentiel à Grande Échelle (RGE)<sup>16</sup> ; avoir une précision équivalente à celle de la BD Topo pour une utilisation locale (SCoT) ; avoir une précision et une **cohérence temporelle (notion de millésime)** ; avoir une nomenclature compatible avec les OCS régionales existantes ou en projet (tant que faire se peut) et CLC, et enfin être **mis à jour régulièrement**.

Deux points sont importants ici, le besoin de cohérence temporelle et de mise à jour régulière. La cohérence temporelle impose de traiter dans les plus brefs délais une grande quantité de données ; toutes les données devraient être produites la même année. De plus, la mise à jour régulière est un besoin essentiel des utilisateurs, afin de permettre une prise de décision sur des données les plus récentes possible et un suivi régulier de l'évolution du territoire.

### 1.1.2 Constitution de l'OCS-GE à l'IGN

Dans un premier temps, l'IGN, en concertation avec ses partenaires locaux et nationaux (Centre d'Étude et d'Expertise sur les Risques, l'Environnement, la Mobilité et l'Aménagement (CEREMA), Direction générale de l'Aménagement du Logement et de la Nature, dépendant du Ministère de l'Écologie, du Développement Durable et de l'Énergie (DGALN)), a constitué une nomenclature nationale répondant aux problématiques évoquées dans la section 1.1.1 : c'est le projet occupation du sol à grande échelle (OCS-GE). Afin de discerner l'occupation du sol et l'usage du sol, cette nomenclature comporte quatre dimensions : la couverture du sol, l'usage du sol, les éléments de morphologie et les éléments de caractérisation. En particulier, la dimension correspondant à la couverture du sol est hiérarchisée en quatre niveaux. Elle est compatible avec CLC et est composée de 24 classes au niveau le plus fin. Le détail de ces classes est indiqué dans le Tableau A.2.

Dans un second temps, une méthode de création de la BD a été définie à l'IGN. Cette méthode s'appuie sur un ensemble de BD pré-existantes, provenant soit de l'IGN (base de données Unifiée (topographique) de l'IGN (BD-Unie), base de données Forêts (végétation) de l'IGN (BD-Forêt), ...), soit de BD partenariales (Registre Parcellaire Graphique (RPG), Vignes, ...). La classe *route* de la BD-Unie est utilisée en priorité afin de former l'ossature, ensemble d'objets sensés demeurer fixe dans le temps et définissant des zones stables. Cette ossature doit permettre le suivi d'indicateurs. Puis, les *bâtiments*, les *réseaux ferrés* et l'*hydrologie* sont également extraits de la BD-Unie. Les cultures provenant du RPG et la végétation, provenant soit de la BD-Unie, soit de la BD-Forêt, sont intégrées avec la plus faible priorité. L'utilisation de BDs thématiques, à supports indépendants, peut introduire des erreurs de type topologique et une partie non négligeable de zones non-couvertes. De plus, un certain nombre d'erreurs, dues à l'ancienneté de ces mêmes BD, est présent dans cette version automatique.

Dans un troisième temps, la BD générée automatiquement est traitée manuellement par des opérateurs afin de corriger les erreurs citées précédemment.

---

16. <http://professionnels.ign.fr/rge>

L'étape de correction d'erreurs d'actualité et de complétion est réalisée par photo-interprétation à partir d'une ortho-image aérienne (résolution de 0,5 m) acquise sur la zone. Cette étape est actuellement la plus chronophage pour les opérateurs ( $< 2 \text{ km}^2/\text{h}$ ) et donc la plus onéreuse. Le résultat de cette opération est visible sur la Figure 1.5. Cette BD est disponible sur le site internet de l'IGN<sup>17</sup>.

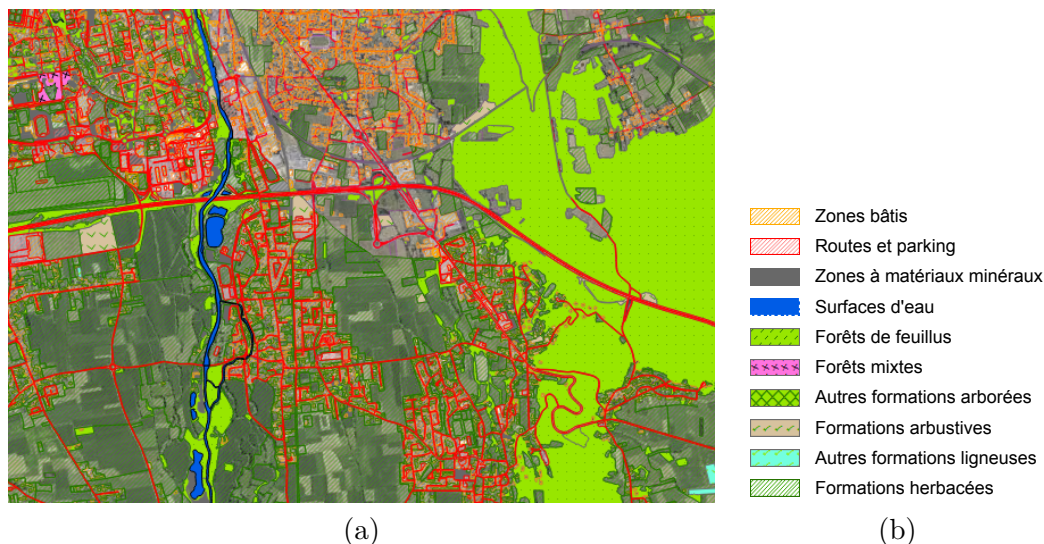


FIGURE 1.5 – Occupation du sol à grande échelle produite par l'IGN (a). La légende (b) est identique à celle du Tableau A.2.

### 1.1.3 Besoin de complétion et de mise-à-jour

Dans les paragraphes précédents, nous avons pu constater un double besoin de complétion et de mise-à-jour qui sera détaillé et analysé ci-après.

En effet, le processus de production de la BD d'OCS-GE de l'IGN, mais également de toutes BDs produites par agrégation de différentes données existantes, nécessite une phase de complétion (sous-section 1.1.2). En effet, dans cette phase d'initialisation, les données pré-existantes utilisées peuvent ne pas couvrir l'ensemble du territoire. Ce besoin est anecdotique dans la mesure où il ne concerne que la première itération, mais il mérite d'être signalé, car à l'échelle du pays il devient non négligeable.

Par ailleurs, les utilisateurs de BD d'OCS expriment clairement et de manière récurrente un besoin de données qui soient (1) mises à jour le plus régulièrement possible et (2) millésimées, c'est-à-dire, dont l'année de production est la même sur l'ensemble du territoire (section 1.1.1). Et beaucoup d'initiatives, comme CLC à l'échelle européenne ou le MOS à l'échelle régionale, fournissent de manière régulière, soit une nouvelle version de leurs données (et le besoin en

17. <http://pro.ign.fr/ocsg>

complétion est de nouveau présent), soit une carte des changements existants entre la dernière version de la BD et la version actuelle.

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

Ainsi, il est nécessaire de mettre en place des méthodes de mise à jour de telles BDs qui seront capables d'automatiser en partie le processus, tout en permettant l'intervention ponctuelle d'opérateurs. Nous verrons dans le chapitre suivant quel type de données peut être utilisé pour répondre à ce besoin.

## 1.2 Évolution des données satellite et nouveaux capteurs très haute résolution

Afin de donner un aperçu de l'évolution des capteurs optiques spatiaux, la série de satellites de télédétection, Satellite Pour l'Observation de la Terre (SPOT) (développée par le Centre National d'Études Spatiales (CNES) en collaboration avec la Belgique et la Suède) est prise pour exemple dans la première subsection de ce chapitre (1.2.1). Puis les capteurs très haute résolution (THR), comme les satellites Pléiades, qui sont l'objet principal de ce manuscrit seront détaillés dans une seconde subsection (1.2.2).

### 1.2.1 Évolution des capteurs optiques spatiaux

Le CNES dispose d'une longue expérience dans les satellites de télédétection ; en effet, il a développé son premier satellite SPOT 1 à la fin des années 1980. SPOT 1 a été suivi par deux autres (SPOT 2 & 3), lancés respectivement en 1990 et 1993. Ces trois satellites avaient des caractéristiques identiques, ils étaient équipés de deux instruments imageurs (HRV - Haute Résolution Visible - 1 et 2), leur permettant d'acquérir des images panchromatiques à 10 m de résolution et des images multispectrales trois canaux (vert, rouge et proche infrarouge) à 20 m de résolution. En 1998, le CNES lance SPOT 4, ce nouveau capteur dispose également d'une résolution de 10 m en panchromatique et 20 m en multispectral, mais l'image est enrichie d'une bande dans le moyen infrarouge. Ces données ont servis, par exemple pour le suivi des dégradations forestières [Souza, 2003].

Quatre ans plus tard, c'est au tour de SPOT 5 d'être lancé. Ce dernier possède un nouvel instrument HRG (Haute Résolution Géométrique) lui permettant, via un couplage de deux capteurs, d'obtenir une image à 2,5 m de résolution

(super-mode panchromatique), 5 m en panchromatique et 10 m en multispectral (vert, rouge, proche infrarouge et moyen infrarouge). L'amélioration de la résolution a permis des applications variées, comme l'estimation de paramètres biophysiques forestiers [Wolter et al., 2009], le suivi de la fonte des glaciers [Pieczonka et al., 2013], ou encore la classification d'occupation du sol [Duro et al., 2012]. Enfin, la dernière génération de SPOT est composée de satellites, SPOT 6 lancé en 2012 et SPOT 7 qui doit être lancé en 2014. La résolution de ces satellites est de 1,5 m en panchromatique et couleurs et de 6 m en multispectral (bleu, vert, rouge, proche infrarouge).

Ainsi, entre 1986 et 2012 la résolution des satellites de télédétection civile a été améliorée d'un facteur presque égal à 7 (Tableau 1.1 et Figure 1.6). Les autres satellites comme la série LANDSAT et WORLDVIEW ayant suivi pratiquement la même évolution, n'ont pas été détaillés ici. Un panorama plus général des différents satellites de télédétection et de leurs utilisations est disponible dans Rogan et Chen [2004]; Belward et Skoien [2014]. Enfin, une autre série de satellites permet d'améliorer encore cette résolution : Pléiades (*cf.* subsection suivante). Mais le principe de ce satellite n'est plus de couvrir de grandes surfaces, mais d'acquérir des zones d'intérêts avec une grande précision et si besoin avec une couverture très régulière (jusqu'à une fois par jour).

Dans l'avenir, cette tendance devrait continuer, en effet, le CNES a annoncé en 2013 le lancement du projet Observation de la Terre Optique Super Résolue (OTOS), qui doit permettre l'acquisition d'images d'une résolution de 0,2 ou 0,3 m à l'horizon du milieu de la prochaine décennie. Par ailleurs, Digital-Globe a lancé le troisième satellite de la série Worldview le 13 août 2014. Ce satellite fournit d'ores et déjà des images panchromatiques à 0,31 m de résolution et des images super-spectrales (8 bandes) à 1,24 m de résolution [Pacifiçi et al., 2014], permettant d'envisager des gains de performance dans les classifications d'OCS [Longbotham et al., 2014]. Par ailleurs, une nouvelle tendance apparaît ces dernières années, il s'agit des micro-satellites comme le Flock 1, de la société Planet<sup>18</sup>, ou des nano-satellites (CubeSat), comme ceux de Skybox Imaging<sup>19</sup>. Ces satellites à faible coût, permettent la création de constellations comportant un grand nombre de satellites (18 pour le Flock 1) et donc l'acquisition d'images à faible coup et avec une grande actualité.

## 1.2.2 Les capteurs très haute résolution

L'évolution des capteurs satellite a permis d'obtenir des images à résolution sub-métrique, dites très haute résolution (THR); c'est notamment le cas des satellites Pléiades (1A et 1B). Cependant, ces satellites ne sont pas les seuls dans le domaine, par exemple, Worldview-2 (et plus récemment le 3), GeoEye-1 ou Quickbird ont des résolutions équivalentes.

Les satellites Pléiades 1A et 1B ont été lancés respectivement en 2011 et

---

18. <http://www.planet.com/flock1/>

19. <http://www.skyboximaging.com>

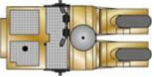
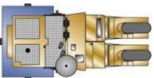
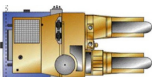


Lancement Masse Durée de vie Altitude Fauchée Revisite Résolutions PAN Résolutions XS Bandes Spectrales (nm)		<b>SPOT 1,2,3</b>	1986-1993 1800 kg 3 ans 822 km		<b>SPOT 4</b>	1998 2760 kg 5 ans 822 km 60 km		<b>SPOT 5</b>	2002 3000 kg 5 ans 822 km 60 km		<b>SPOT 6,7</b>	2012/2014 800 kg 5 ans 694 km 60 km		<b>Pleiades</b>	2011/2012 980 kg 5 ans 694 km 20 km
			3 j 10 m 20 m		2 j 10 m 20 m		2 j 2,5 m ou 5 m 10 m		2 j 1,5 m 6 m		1 j 0,7 m 2,8 m				
			500-730 -		610-680 -		480-710 -		450-750 455-520		470-830 430-550				
			500-590 610-680 780-890		500-590 610-680 780-890		500-590 610-680 780-890		530-600 620-690 760-890		500-620 590-710 740-940				

Tableau 1.1 – Aperçu de l'évolution des caractéristiques des satellites SPOT 1 à 6 et Pleiades.



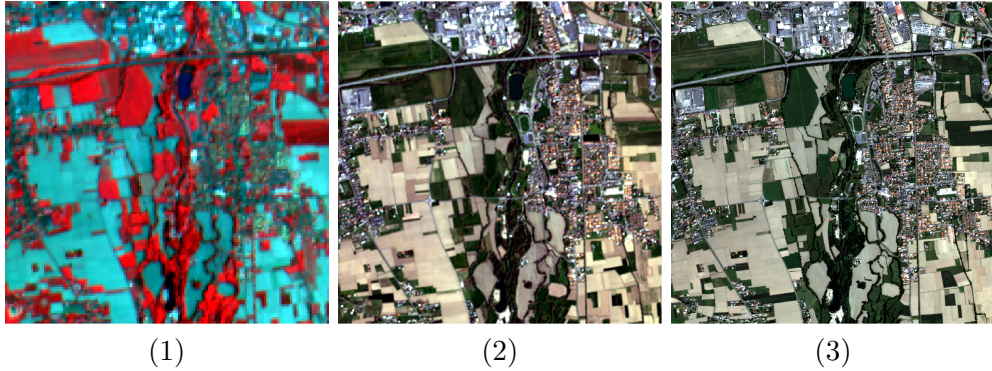


FIGURE 1.6 – Aperçu de l'évolution des images acquises par les satellites SPOT 4 en NIR,R,V le 16/06/2013 (1), SPOT 6 en R,V,B le 14/04/2014 (2) et Pléiades en R,V,B, le 29/05/2012 (3), dans la proche banlieue de Tarbes (65).

2012 (Tableau 1.1). Ils possèdent un capteur optique d'une résolution de 0,7 m en panchromatique et 2,8 m en multi-spectral (bleu, vert, rouge, infrarouge). Mais les images livrées aux utilisateurs sont ré-échantillonnées à une résolution de 0,5 m. À mi-chemin entre les images aériennes et les satellites moins résolus comme SPOT 6, les satellites Pléiades permettent d'obtenir une couverture régulière de zones d'intérêt, ou d'acquérir rapidement une image sur une zone (post-catastrophe) avec une grande résolution. En revanche, ils n'atteignent pas la résolution des données aériennes ( $<0,25$  m) ni la capacité de couvrir de larges zones (nationale) en peu de temps. Par ailleurs, les contraintes de programmation et de coût imposent souvent l'acquisition de données monoscopiques, alors que ces satellites ont une habileté suffisante pour l'acquisition de données stéréoscopiques.

La très grande résolution de ces satellites et leur capacité d'acquisition stéréoscopique permet une description fine du territoire, avec des applications variées comme la cartographie de précision [Pausader et al., 2013], la caractérisation de la densité urbaine [Bouffier et al., 2014], la détection d'éléments de petites tailles comme les haies [Fauvel et al., 2014], ou encore la caractérisation des parcelles agricoles [Vaudour et al., 2014]. Un numéro spécial de la Revue Française de Photogrammétrie et de Télédétection est consacré aux différentes applications rendues possibles par Pléiades [Tinel, 2014].

Ainsi, nous avons vu dans ce chapitre que les satellites actuels permettent, grâce à leur résolution spatiale et leur dynamique spectrale, une description fine de la couverture du sol d'un territoire. Ainsi ces satellites, et en particulier les satellites Pléiades devraient permettre de couvrir les besoins des utilisateurs vus dans le chapitre précédent. Dans ce contexte, nous détaillerons dans le chapitre suivant la problématique précise de nos travaux de recherche au sujet de la mise à jour de base de données d'occupation du sol à partir d'image très haute résolution.

## 1.3 Problématique et approche proposée

### 1.3.1 Problématique

La problématique traitée dans ce manuscrit porte sur la mise à jour de bases de données (BDs) d’occupation du sol (OCS), besoin fort, exprimé par les utilisateurs de ce type de données (section 1.1). En effet, nous avons pu constater dans la section 1.1 que le besoin de mise à jour et de cohérence temporelle des données (notion de millésime) nécessite la mise en place de méthodes les plus automatiques possible, afin de traiter rapidement des zones étendues. Par ailleurs, la section 1.2 montre d’une part l’émergence d’un grand nombre de capteurs satellite avec des résolutions de plus en plus fines, et, d’autre part, leurs utilisations grandissantes dans le domaine de la télédétection en général et plus particulièrement dans le suivi de la couverture du sol. Ainsi, il paraît raisonnable d’utiliser de telles images afin de mettre à jour des BDs d’OCS-GE.

Nous supposons ici que les changements sont minoritaires dans les données à mettre à jour. Il ne s’agit pas de faire de la détection de changement de type post-catastrophe, mais bien d’une mise à jour dans le cadre d’une évolution normale et continue d’un territoire. De plus, nous supposons également que l’image et la BD à mettre à jour sont correctement recalées, hypothèse valable au vu des nombreuses méthodes de recalage existantes [Trias-Sanz, 2006a; Clery et al., 2014]. Ainsi, les données à mettre à jour pourront être utilisées dans la phase d’apprentissage, en portant une attention particulière à leurs éventuels changements.

Cependant, trois points de questionnement peuvent être soulignés :

- la fréquence de mise à jour souhaitée par les utilisateurs étant élevée (annuelle), la méthode devra être la plus automatique possible ;
- une grande variété de bases de données d’occupation du sol existe (en terme de nomenclature et de précision) et un ensemble d’images, éventuellement d’un même capteur, peut souffrir de variabilité spatiale comme temporelle (changement de condition climatique, ...) : la méthode devra ainsi être capable de s’adapter à cette double variabilité ;
- les méthodes de télédétection actuelles souffrent généralement d’un manque de robustesse, en particulier lorsque les thèmes de la BD sont complexes (fortes inhomogénéités) : la méthode proposée devra s’appliquer à réduire au maximum les erreurs liées à l’utilisation de méthodes de classification.

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

*Ainsi, l’objectif de nos recherches est de proposer une méthode pour la mise à jour de base de données géographiques en milieux naturels par utilisation de données monoscopiques, acquises régulièrement à une résolution sub-métrique et d’étudier les limites de ce type de données.*



### 1.3.2 Stratégie générale

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

- apprentissage sur des **données imparfaites** ;
- adaptation à des **classes variées** et à **différents types d’images** ;
- amélioration de la **robustesse** des classifications par la prise en compte des **thèmes inhomogènes**.

Ainsi, une méthode d’apprentissage multiple, nommée Multi Level, Multi Object Learning (MLMOL) est proposée. Cette méthode repose d’une part sur la sélection des points d’apprentissage dans la BD à mettre à jour et, d’autre part, sur la multiplication des classifications et leur fusion. La sélection des points d’apprentissage et la fusion des classifications permettent de s’affranchir d’éventuels problèmes dans la base de données d’apprentissage (problèmes généralement dus aux changements que l’on cherche à détecter, mais qui peuvent également provenir d’un décalage entre la BD et l’image). Par ailleurs, la multiplication des classifications permet de rendre notre méthode plus robuste que des algorithmes de classification classiques, en prenant en compte l’inhomogénéité des thèmes.

Puis, une chaîne de traitements, intégrant la méthode MLMOL, nommée Land-cover databases Updating by Processing Images in Natural environment ( $\mathbb{L}\mathbb{P}\mathbb{N}$ ), a été construite (*cf.* Figure 1.7). Elle est caractérisée par une forte modularité : une étape de sélection d’attributs par thème et l’utilisation de classifications de type « un-contre-tous » permet à notre méthode de s’adapter au mieux aux classes très hétérogènes qui composent les BD d’OCS, et aux données de télédétection variées disponibles pour réaliser cette mise-à-jour.

### 1.3.3 Organisation du manuscrit

À la suite de la partie courante (Partie I), ce manuscrit est composé de trois parties indépendantes. Dans un premier temps, une partie État-de-l’art (Partie II) décrit les méthodes existantes dans le domaine de la détection de changements (chapitre 2), puis les algorithmes classiques en télédétection mis en œuvre dans notre méthode : les attributs de classification (chapitre 3), les méthodes de sélection d’attributs (chapitre 4) et de classification (chapitre 5). La partie suivante (Partie III) décrit d’abord la méthode d’apprentissage MLMOL proposée et son expérimentation sur des données simulées permettant de s’abstraire des problèmes liés aux attributs de classification (chapitre 6), puis l’intégration de cette méthode dans la chaîne de traitement  $\mathbb{L}\mathbb{P}\mathbb{N}$ , en s’appuyant sur un jeu de données générées à partir d’image Pléiades labellisée (chapitre 7). La mise en œuvre de notre méthode pour la mise à jour d’un jeu de données d’OCS-GE à partir d’une image satellite Pléiades (chapitre 8) et l’ouverture sur de nouveaux jeux de données composés de différents capteurs satellite - RapidEye et SPOT 6 (différentes résolutions, multi-temporel) (chapitre 9) - sont regroupés dans la Partie IV. Enfin, les conclusions et perspectives sont dressées

dans la dernière partie (Partie V).

LUPIN

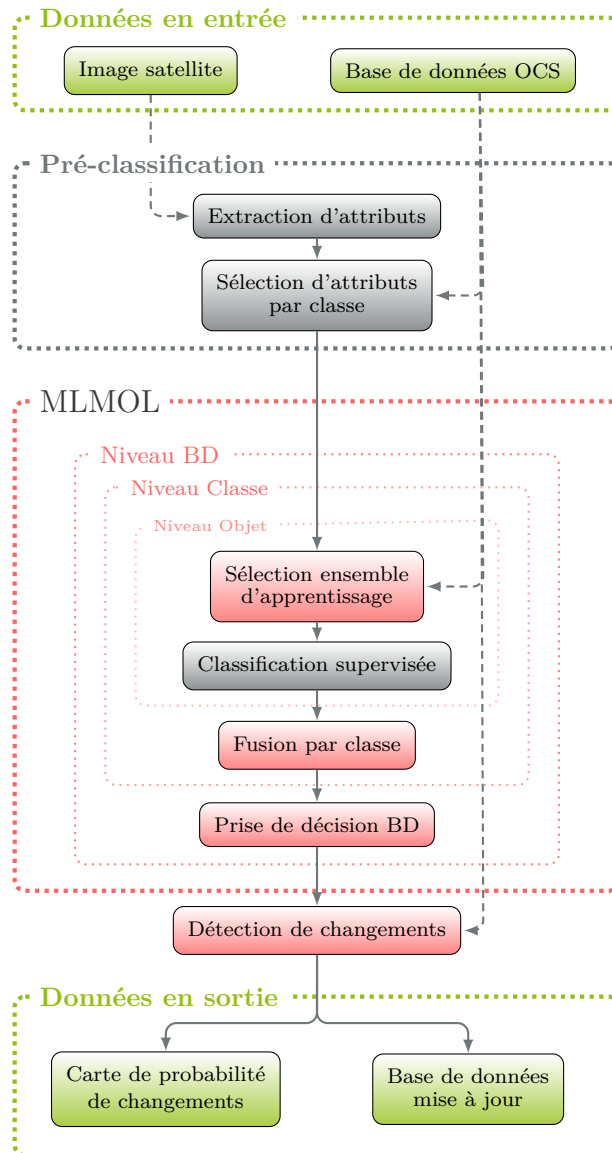


FIGURE 1.7 – Schéma général de la chaîne de traitements pour la mise à jour de base de données d’occupation du sol LUPIN.


Deuxième partie

État de l'art



# Méthodes de détection de changements et de mise à jour de bases de données en télédétection

---



1

## Sommaire

---

<b>3.1</b>	<b>Attributs spectraux</b>	<b>30</b>
3.1.1	Thématiques	31
3.1.2	Espaces colorimétriques	32
<b>3.2</b>	<b>Attributs de texture</b>	<b>34</b>
3.2.1	Analyse statistique	35
3.2.2	Analyse fréquentielle	41
<b>3.3</b>	<b>Attributs géométriques et notion d'objet</b>	<b>47</b>
3.3.1	Attributs de forme	47
3.3.2	Attributs morphologiques	47
3.3.3	Notion d'objet (ou région)	49
<b>3.4</b>	<b>Conclusion</b>	<b>51</b>

---



---

1. Détection de changements sur des cartes, Source : <http://10decoeur.pagesperso-orange.fr>

La détection de changements consiste à fournir des indicateurs de changements entre deux (ou plusieurs) jeux de données. Par exemple, il peut s'agir de trouver les différences entre deux images avant et après un événement (inondation, feu de forêt, ...). Lorsque cette détection concerne non plus deux images, mais une image et une BD géographique, on parle alors de mise à jour de BD. La détection de changements est une part importante des problématiques abordées en télédétection : plusieurs chapitres de livres traitent de ce sujet [Hecheltjen et al., 2014; Mercier et Tupin, 2014]. Dans ce dernier, les auteurs précisent que la détection de changements peut concerner soit un changement abrupt, soit un changement lent et évolutif et s'intéressent plus particulièrement au premier type. De plus, une littérature abondante existe dans le domaine de la détection de changements et plusieurs panoramas des méthodes existantes sont disponibles [Coppin et al., 2004; Hussain et al., 2013].

En particulier, Lu et al. [2014] décrivent le processus générique commun à l'ensemble des méthodes de détection de changements. De manière générale, la première étape consiste en une description détaillée de la problématique (nature du changement, localisation et étendue de la zone d'intérêt). La définition et la modélisation de la nature du changement recherché joue un rôle important dans les étapes suivantes [Bruzzone et Bovolo, 2012]. Cette étude permet, dans un deuxième temps, de définir les données de télédétection les plus appropriées pour le problème (choix de données optiques, radar ou lidar, choix de la résolution, ...).

Une fois les données choisies, une étape de prétraitement des données est généralement nécessaire. Elle consiste en une correction géométrique et radiométrique des images afin d'assurer la cohérence des données disponibles. En effet, la géométrie des données, et en particulier le recalage des données entre-elles [Bovolo et al., 2009] et les différences radiométriques [Velloso et al., 2002; Inamdar et al., 2008], ont un impact important sur la qualité des résultats. Différents travaux cherchent à réduire cet impact [Ding et al., 2010; Thomas et al., 2012].

Après une étape d'extraction d'attributs de classification à partir des données, la méthode de détection de changements, proprement dite, est appliquée. Enfin, une étape d'évaluation des résultats est également nécessaire. Cependant, cette dernière étape repose sur la création d'une vérité terrain de changements, qui peut être longue et difficile à réaliser.

Concernant la méthode de détection de changements à proprement parler, on peut distinguer différentes approches :

- binaire : la classification se limite à seulement deux étiquettes (changement / non-changement) ;
- trajectoire de changements : ce type de méthodes décrit la provenance et la destination de chaque entité, et permet ainsi une analyse plus fine des changements ;
- spécifique : le changement étudié est limité à un type de changements particulier (déforestation, urbanisation, extension agricole) ;

- continue : dans ce dernier cas, une variable continue est étudiée, cela peut être, par exemple, l'état d'une forêt impactée par une maladie, des sécheresses ou des incendies.

On s'intéressera ici en particulier aux méthodes de détection de changements binaires et aux méthodes à trajectoire de changements. Les premières peuvent suffire pour réduire les zones d'inspection d'un opérateur, mais les secondes répondent mieux à notre problématique de mise à jour de base de données d'occupation du sol, car elles permettent, en plus, de proposer une étiquette du nouveau thème sur une zone de changement.

En fonction des études, ces méthodes de détection de changements peuvent être classées en deux catégories qui seront détaillées dans les sections suivantes : la détection de changements entre deux (ou plusieurs) images et la détection de changements entre une base de données existante et une nouvelle image.

## 2.1 Entre deux ou plusieurs images

Il convient de discerner les méthodes utilisant un couple d'images, de celles utilisant une série temporelle d'images. Dans le premier cas, on s'intéressera aux changements existants entre deux dates, alors que dans le deuxième cas l'évolution et la quantification du changement peuvent être étudiées plus précisément.

### 2.1.1 Couple d'images

La détection de changements entre deux images est apparue il y a bientôt 30 ans, avec des méthodes dites de pré-classification. La première idée fut de comparer directement les canaux des deux images (par différence mathématique) : par exemple sur des zones urbaines avec des données SPOT HRV [Quarmby et Cushnie, 1989] ou sur des zones forestières [Coppin et Bauer, 1996]. Puis, des indices calculés sur les images ont permis d'améliorer ce type de méthodes. Par exemple, Wilson et Sader [2002] utilisent des indices de végétation pour s'intéresser à la forêt, et Erener et Düzgün [2009] des indices de texture pour de l'occupation du sol. Cependant ces méthodes ne permettent pas d'obtenir la nature du changement, mais se limitent à une classification binaire en changement / non-changement. Par ailleurs, elles restent très sensibles aux variations radiométriques des images dues à des changements atmosphériques ou de conditions climatiques (ombres, ensoleillement). Volpi [2013] propose ainsi une méthode d'alignement statistique afin de résoudre ce problème et de permettre, en plus, la comparaison d'images issues de différents capteurs.

Par suite, avec l'avènement des méthodes de classification supervisées, une méthode dite de comparaison post-classification a été introduite. Ici, chacune des images est classifiée de manière indépendante, puis les deux classifications sont comparées *a posteriori* [Miller et al., 1998; Ghosh et al., 2011]. Cette méthode permet de réduire les erreurs provenant de variations radiométriques dans les images et introduit la notion de trajectoire de changements (origine et destina-

tion de l'élément changeant). Cependant, cette méthode nécessite des données d'apprentissage et reste tributaire de la qualité des classifications.

Les méthodes de classification supervisées peuvent, également, être utilisées directement pour une classification binaire changement / non changement. Dans ce cas, les deux images sont fusionnées afin de ne former qu'un seul jeu de données. La classification peut être effectuée, par exemple, par Séparateur à Vaste Marge (SVM) [Huang et al., 2008; Bovolo et al., 2008] ou par Forêts Aléatoires (FA) [Pal, 2005; Sesnie et al., 2008; Smith, 2010] (ces méthodes de classification sont détaillées dans le chapitre 5). Cependant, il est difficile de trouver des exemples d'apprentissage pour l'ensemble des changements pouvant exister, ce qui limite grandement ce type de méthodes.

### 2.1.2 Série d'images

L'utilisation de séries temporelles d'images permet d'affiner les résultats des méthodes de détection de changements. Cependant elle introduit également le problème de gestion du volume important de données : le nombre d'images sur une zone est souvent supérieur à 10, mais dépasse rarement les 100. Dans le chapitre consacré à la détection de changements Mercier et Tupin [2014] évoquent deux méthodes de détection de changements fondées sur des séries temporelles. La première méthode proposée consiste à réaliser une Analyse en Composantes Principales (ACP) de la réunion de l'ensemble des images disponibles sur la zone d'étude. La première composante de l'ACP, correspondant à la plus grande valeur propre, fournit un aperçu de la tendance générale (invariant temporel) de la série d'images. Les composantes suivantes permettent de rendre les changements visibles. La seconde méthode décrite, issue des algorithmes de fouille de données, s'intéresse à la répétition de motifs dans les séries temporelles d'images [Le Men, 2009; Petitjean et al., 2010]. Appliquée à des images à très haute résolution, cette méthode permet de détecter des changements brutaux comme les labours et l'enneigement, mais aussi des changements plus lents comme l'évolution des cultures. Enfin, les motifs temporels fréquents peuvent être détectés par des approches non supervisées [Julea et al., 2011].

Les séries temporelles peuvent également être utilisées pour la mise à jour de BDs. Par exemple, Demir et al. [2013] proposent une méthode de transfert d'apprentissage pour la mise à jour de BD OCS. La méthode nécessite d'avoir une image (source) et une BD correspondante, ainsi qu'une (ou plusieurs) image(s) pour la mise à jour (images cibles). Dans un premier temps, une méthode non-supervisée de détection de changements entre l'image source et l'image cible est appliquée. Puis, les étiquettes de la BD initiale, sur les zones de non changement de l'image source, sont propagées sur l'image cible. Enfin, l'ensemble d'apprentissage de l'image cible est optimisé avec une méthode d'apprentissage actif.

Enfin, certaines méthodes permettent de détecter des changements entre deux séries temporelles, dans ce domaine, on peut citer les méthodes utilisant une



mesure de similarité entre séries temporelles, comme la mesure Dynamic Time Warping (DTW). En effet, cette mesure permet d'utiliser des séries temporelles échantillonnées de façon irrégulière [Petitjean et al., 2012].

## 2.2 Entre une base de données et une (ou plusieurs) image(s)

Malgré l'existence d'un grand nombre de BD géographiques, en particulier dans les pays développés, et une demande grandissante pour leurs mises à jour, la littérature sur ce sujet est beaucoup moins abondante que celle sur la détection de changements image/image présentée ci-avant. Ce constat est d'autant plus marquant que les méthodes de mise à jour, actuellement utilisées en production, sont essentiellement basées sur de la photo-interprétation (voir section 1.1), qui est un processus fastidieux, long et onéreux.

De manière générale, les méthodes existantes en sont encore au stade de la recherche et ne concernent que des thèmes spécifiques. Par exemple, le thème *bâti* est l'un des thèmes les plus traités. Le Bris et Chehata [2011] proposent une méthode de classification couplant les attributs spectraux classiques avec l'utilisation de la différence entre un MNT et un MNS de corrélation. Cette différence entre MNT et MNS est également utilisée dans les travaux de Champion et al. [2010], afin de détecter les bâtiments détruits, puis de rechercher les nouveaux bâtiments. Par ailleurs, un nombre important de travaux cherchent à extraire les réseaux routiers, par exemple en détectant des formes rectilignes dans des images SAR [Tupin et al., 1998], ou en utilisant des opérateurs de morphologie mathématique [Lefèvre et Courtrai, 2014].

De manière analogue, Poulain [2010] propose une méthode générique de vérification des objets d'une BD et de détection de nouveaux objets, à partir de différentes données de télédétection et l'applique à la détection de routes et de bâtiments à partir de données optiques haute et très haute résolution et des données SAR. La méthode est fondée sur l'extraction de différents descripteurs permettant de décrire ces objets et d'un modèle de type Dempster-Shafer (théorie des croyances) pour prendre en compte l'imprécision et l'incertitude des descripteurs précédents. Bien que générique, l'utilisateur doit fournir les bons descripteurs pour chaque type d'objet à mettre à jour. Ziems et al. [2012] proposent également d'utiliser la théorie des croyances afin de fusionner différentes méthodes de vérifications de routes pour améliorer leurs résultats. La méthode s'appuie sur une image THR et un Modèle Numérique de Surface (MNS). Généralement, ce type de méthode souffre de la complexité algorithmique de la théorie des croyances et est difficilement envisageable pour le passage à l'échelle.

Par suite, les méthodes spécifiques et automatiques peuvent être regroupées dans un système expert semi-automatique de mise à jour de BD géographique [Helmholz et al., 2012]. Ce système cherche à mettre à jour par des méthodes spécifiques, chaque thème de la BD. Des indicateurs de changements / non

changements, sous forme de feux vert / rouge, sont transmis à un opérateur pour être validés manuellement.

D'autres méthodes utilisent la BD initiale comme une donnée d'entraînement pour un classifieur, il peut s'agir de classification au pixel ou orienté-objet [Bouziani et al., 2010; Walter, 2004; Hofmann et al., 2008; Radoux, 2010; Chen et al., 2012]. Les objets de la BD utilisés pour l'apprentissage sont filtrés par un critère de correspondance entre les frontières de ces derniers et les gradients de l'image [Marçal et al., 2005]. Dans la même catégorie de méthodes, on peut citer l'initiative du projet DeCOVER pour la mise à jour de CLC du GMES [Buck, 2010; Lohmann et al., 2008]. Dans leur approche, deux scénarii sont envisagés : une détection de changements image-image et une détection de changements BD-image, mais le second est privilégié. Dans ce scénario, une base de connaissance de l'apparence des objets est d'abord construite, puis ces données servent à classifier une nouvelle image. Par ailleurs, Domenech et Mallet [2014] proposent une méthode de mise à jour de BD d'OCS par utilisation conjointe d'images aériennes et de données Lidar. Cependant, ces classifications peuvent souffrir de différents problèmes : soit elles requièrent l'utilisation d'une segmentation et sont donc tributaires de la qualité de cette dernière, soit elles sont fondées sur une méthode de classification classique et peinent généralement à appréhender les multiples apparences des objets d'un même thème ou sont pénalisées dans les différences d'illumination de la scène (ombres), soit elles requièrent l'utilisation de données stéréoscopiques pour discerner les objets du sol et de ceux du sur-sol (particulièrement en milieu urbain).

## 2.3 Conclusion

Dans ce chapitre, nous avons vu que les méthodes de détection de changements pouvaient être classées en deux familles : la détection de changements entre deux ou plusieurs images (section 2.1) ou entre une BD existante et une image (section 2.2).

Par rapport à notre problématique de mise à jour et de détection de changements, la première famille de méthodes nécessite d'avoir une image acquise à la même date que celle de création de la BD. Ceci n'est pas encore possible, puisque dans l'état actuel, la BD OCS à mettre à jour ne possède pas de millésime. En effet, elle est issue de la fusion de BD exogènes, créées et mises à jour à des dates différentes. Cependant, il pourrait être intéressant, dans le cas où l'on dispose d'une base de données millésimée et d'une image correspondant à cette date, d'utiliser une méthode de détection de changements image-image afin de pouvoir réduire les zones inspectées par photo-interprétation et de focaliser la phase d'apprentissage d'une nouvelle classification sur les zones de non-changements.

Dans nos travaux, nous nous pencherons donc plus particulièrement sur les méthodes de détection de changements entre une BD et une image. Cependant, comme on a pu le voir précédemment, les méthodes disponibles sont soit spécialisées sur un thème spécifique (généralement sur des thèmes urbains : routes,

bâtiments), soit reposent sur la méthode classique d'apprentissage / classification et souffrent donc d'inconvénients liés principalement à l'inhomogénéité des thèmes.


Ainsi, notre méthode a été développée pour s'adapter automatiquement et sans *a priori* aux thèmes de la BD d'OCS à mettre à jour. Cette indépendance aux thèmes est garantie par l'introduction d'un grand nombre d'attributs suivie d'une étape de sélection d'attributs par thème et par l'utilisation de classifications de type « un-contre-tous », permettant de discriminer au mieux chacun des thèmes composant la BD. Par ailleurs, la robustesse de notre méthode face aux thèmes inhomogènes est assurée par la multiplication des classifications (une par objet de la BD) et par une double étape de fusion de ces classifications (au niveau du thème et de la BD).

La prochaine étape, sera donc la description des attributs de classification existant et leurs cas d'utilisations.



# Quels attributs pour la classification d'images à très haute résolution spatiale ?

---



## Sommaire

---

<b>4.1</b>	<b>Réduction de dimension</b> . . . . .	<b>54</b>
4.1.1	Méthodes linéaires . . . . .	54
4.1.2	Méthodes non-linéaires . . . . .	55
<b>4.2</b>	<b>Sélection d'attributs</b> . . . . .	<b>56</b>
4.2.1	Méthodes d'exploration . . . . .	57
4.2.2	Méthodes d'évaluation . . . . .	58
4.2.3	Sélection d'attributs en télédétection . . . . .	58
<b>4.3</b>	<b>Conclusion</b> . . . . .	<b>59</b>

---

Les méthodes de détection de changements et plus particulièrement de mise à jour de BD vues dans le chapitre précédent, ainsi que celle qui est proposée dans ce document, essaient de tirer profit au maximum de l'image (ou de la série d'images) couvrant la zone à mettre à jour, en utilisant des méthodes de classification supervisées. Or, l'information contenue dans les différents canaux de l'image correspondant à autant de bandes spectrales - généralement dans le rouge, le vert, le bleu et le proche-infrarouge - ne permet pas de discerner de façon pertinente et exhaustive les thèmes qui composent nos bases de données. Ainsi, une grande partie de la littérature en lien avec la télédétection s'intéresse à l'extraction maximale d'information des données disponibles, ici des images satellite. Ces informations, appelées attributs, primitives ou caractéristiques, sont calculées à partir d'un ou plusieurs canaux de l'image initiale, à partir d'un pixel ou d'un voisinage de chaque pixel. Plusieurs types d'attributs peuvent être discernés et seront détaillés dans les sections suivantes :

- les attributs spectraux (section 3.1) : issus de combinaisons des différents canaux de l'image ;
- les attributs de texture (section 3.2) : permettant de décrire le comportement local de l'image au voisinage d'un pixel ;
- les attributs géométriques (section 3.3) : prenant en compte des notions de taille et de forme de motifs au voisinage d'un pixel ou sur une région (issue, par exemple, d'une segmentation de l'image).

Une grande partie des attributs décrits dans ce chapitre ont été calculés sur un extrait d'une image Pléiades acquise en mai 2012 et en couvrant un paysage très varié : une zone bâtie clairsemée desservie par un réseau routier de proximité (à l'est), une voie ferrée traversant l'image, d'une parcelle forestière (sud-ouest), des champs et prairies, ainsi que des haies (*cf.* Figure 3.2).

### 3.1 Attributs spectraux

Les capteurs satellite d'observation de la terre ont été conçus afin de couvrir largement le spectre du visible. Ainsi les images fournies sont composées de différents canaux, correspondant à autant de bandes spectrales (généralement dans le rouge, le vert, le bleu et le proche-infrarouge). L'information issue de ces capteurs optiques (la luminance) est directement liée à la réflectance des objets observés (Figure 3.1). Ainsi, les attributs spectraux sont les premiers à avoir été utilisés, car ils sont les plus proches de la mesure physique et de la perception humaine. Ces attributs peuvent être divisés en deux sous-ensembles. Le premier ensemble correspond aux attributs composés de combinaisons des canaux de l'image initiale et permettant de discerner un thème spécifique (*e.g.*, végétation, eau, bâtiment). Le second est lié à l'utilisation de différents espaces colorimétriques. Ces deux ensembles d'attributs correspondent à deux disciplines différentes à savoir la télédétection et le traitement de l'image, qui se sont rapprochées ces dernières années.




FIGURE 3.1 – Représentation de la réponse spectrale de différents types de couvertures du sol dans le domaine visible et proche-infrarouge.

### 3.1.1 Thématiques

En télédétection, les travaux existants sur les attributs cherchent généralement à discerner un ou plusieurs thèmes spécifiques (*e.g.*, végétation, zones bâties, eau), ou à quantifier un phénomène (*e.g.*, santé, croissance / sénescence de la végétation, stress hydrique), en se fondant sur les comportements spécifiques des objets dans une ou plusieurs parties du spectre électro-magnétique.

La végétation ayant une forte réponse dans le proche infra-rouge (PIR) - phénomène dû à la teneur des plantes en chlorophylle - le canal PIR a été introduit très tôt sur les capteurs spatiaux (Figure 3.2). Ce canal PIR a alors permis de développer des indices permettant de discriminer au mieux la végétation, le plus connu et le plus utilisé étant l'indice Normalized Difference Vegetation Index (NDVI) [Kriegler et Malila, 1969; Rouse, 1974] :

$$\text{NDVI} = \frac{\text{PIR} - \text{R}}{\text{PIR} + \text{R}},$$

où PIR et R sont respectivement les canaux proche infrarouge et rouge. Ainsi, une végétation en bonne santé et avec un couvert dense aura une valeur de NDVI forte, alors qu'une végétation malade, souffrant de sécheresse ou simplement clairsemée aura une valeur faible (Figure 3.2).

Par la suite, beaucoup d'autres indices de végétation ont été proposés comme par exemple le RVI (Ratio Vegetation Index) [Pearson et al., 1976], le PVI (Perpendicular Vegetation Index) [Richardson et Weigand, 1977], ou encore le SAVI (Soil Adjusted Vegetation Index), illustré sur la Figure 3.2 [Huete, 1988]. Ce dernier cherche à améliorer l'indice NDVI dans le cas de zone faiblement couverte par la végétation (<40%) en corrigeant l'influence de la réflectance du sol. Il est défini ainsi :

$$\text{SAVI} = \frac{\text{PIR} - \text{R}}{\text{PIR} + \text{R} + \text{L}} * (1 + \text{L}),$$

où L est le facteur de correction de la réflectance du sol. Ce facteur peut varier entre 0 et 1. Une faible valeur est utilisée lorsque le couvert de végétation verte est fort, on retrouve l'indice NDVI pour  $L = 0$ . Inversement, lorsque ce couvert est faible, on utilise une valeur proche de 1. Généralement, une valeur de 0,5 est utilisée par défaut. D'autres indices de végétation, en particulier pour le suivi de la biomasse ont été définis dans la littérature [Silleos et al., 2006].

Dans la série des indices spectraux spécifiques, on peut également citer des indices prenant en compte les propriétés de l'atmosphère comme ARVI (*Atmospherically Resistant Vegetation Index*) et GEMI (*Global Environment Monitoring Index*) [Rondeaux et al., 1996], des indices plus adaptés aux zones anthropisées et en particulier les bâtiments : indice de brillance (IB) illustré sur la Figure 3.2, et indice de bâtiment (ISU) [Abdellaoui et Rougab, 1997]. Il existe également des attributs spécifiques pour l'eau, comme le SRWI (*Simple Ratio Water Index*) ou le NDWI (*Normalized Difference Water Index*) qui sont décrits dans [Gao, 1996; Zarco-Tejada et Ustin, 2001]. Ainsi, il existe, pour la très grande majorité des thèmes, un ou plusieurs indices spécifiques.

Ces indices ont été utilisés pour des capteurs à moyenne résolution spatiale existant à l'époque de leur création. Cependant ils sont toujours utilisés sur des capteurs THR récents [Bhaskaran et al., 2010; Salehi et al., 2011; Heumann, 2011], soit pour une classification pixel traditionnelle, soit dans de nouvelles approches dites orientées-objet (*cf.* section 3.3) .

Une base de données<sup>2</sup> répertoriant une grande partie des indices existants pour les principaux satellites d'observation de la terre et de leurs applications est décrite dans [Henrich et al., 2009].

### 3.1.2 Espaces colorimétriques

En informatique, les images sont généralement stockées sous la forme d'un tableau de pixels, où chaque pixel dispose de trois composantes : rouge, verte et bleue (RVB). Dans le cas d'images satellite, ces informations proviennent de trois capteurs travaillant chacun dans une longueur d'onde, correspondant à ces trois couleurs (le proche-infra rouge n'est pas utilisé dans cette partie). Ces trois canaux permettent de reconstituer une image couleur, car ils correspondent aux trois types de cônes présents dans l'œil humain, nous permettant de voir en couleur. Ainsi, l'espace à trois dimensions RVB est un espace dit colorimétrique, mais il existe différents espaces de ce type. Par exemple, pour l'impression, où la couleur est rendue par synthèse soustractive (contrairement à la synthèse additive de la lumière), un espace colorimétrique fondé sur les couleurs complémentaires (cyan, magenta et jaune) est utilisé. Par ailleurs, des espaces colorimétriques perceptuels (basés sur des notions subjectives de couleur)

---

2. <http://www.indexdatabase.de/>






FIGURE 3.2 – Extrait d’une image Pléiades. Sur la première ligne : le canal panchromatique et les compositions R-V-B et IR-R-V. Sur la seconde ligne : les indices NDVI, SAVI et IB.

ont été développés : c’est le cas des systèmes TSV (Teinte Saturation Valeur) et TSL (Teinte Saturation Lumière) respectivement HSV (Hue Saturation Value) et HSL (Hue Saturation Lightness) en anglais (Figures 3.3 et 3.4), ou encore du système CIE-LAB développé par la Commission Internationale de l’Éclairage (CIE).



FIGURE 3.3 – Espace colorimétrique TSL (Teinte Saturation Lumière).

Ces espaces colorimétriques sont utilisés comme attributs pour la segmentation multi-étiquettes (problématique proche de la classification). Par exemple Santner et al. [2010] utilisent les espaces niveaux de gris, RVB, TSV et CIE-LAB. Dans le domaine de la télédétection, Trias-Sanz [2006b] présente plusieurs espaces pouvant être utilisés, comme les espaces colorimétriques CIE [Vertan et Boujemaa, 2000; Forsyth et Ponce, 2002; Takamura et Kobayashi, 2002] ou les espaces chromatiques [Faugeras, 1979; Berens et Finlayson, 2000]. Tokarczyk et al. [2015] proposent une méthode de génération automatique et de sélection

d'attributs dans différents espaces colorimétriques. Enfin, une méthode de sélection de l'espace colorimétrique le plus pertinent pour une problématique donnée est proposée dans [Vandenbroucke et al. \[2003\]](#).




FIGURE 3.4 – Extrait de l'image Pléiades de la Figure 3.2 vue dans l'espace colorimétrique TLS : de gauche à droite teinte, saturation et lumière.

## 3.2 Attributs de texture

Les attributs de texture permettent de décrire au mieux le comportement de l'image au voisinage d'un pixel, soit en s'intéressant à la régularité de l'image (image lisse ou rugueuse), soit en caractérisant la répétition de motifs dans ce voisinage. Cette notion simple à énoncer en apparence est en réalité complexe à définir théoriquement [[Forsyth et Ponce, 2002](#)].

Une littérature abondante existe sur le sujet et plusieurs aperçus des méthodes existantes ont été proposés [[Grigorescu et al., 2000](#); [Singh et Singh, 2002](#); [Trias-Sanz, 2006b](#); [Lefebvre, 2011](#)]. Les attributs de texture ont été utilisés dans des domaines très variés comme les images médicales [[Sabu et Ponraj, 2012](#)], la détection de visage [[Louis et Plataniotis, 2011](#)] ou dans le domaine de la télédétection [[Lefebvre et al., 2008](#); [Le Bris, 2012](#)].

D'après [Lefebvre et al. \[2008\]](#), la définition d'une texture repose sur deux paramètres : la notion d'échelle d'observation (micro ou macro) et la notion d'isotropie. L'échelle d'observation joue un rôle important : par exemple, un mur de brique a une macro-texture formée par la répétition et l'alignement des briques (Figure 3.5). Mais chaque brique est caractérisée par une micro-texture (la granulosité de sa surface). L'isotropie décrit la régularité de la répétition d'un éventuel motif dans une ou plusieurs directions. La surface est dite anisotrope en cas de répétition, et isotrope (ou homogène) si la répartition est indépendante de la direction. Dans l'exemple du mur de briques, la macro-texture est anisotrope : toutes les briques sont alignées verticalement et horizontalement, alors que la micro-texture de chaque brique est isotrope : elle n'est pas régulière.

Afin de caractériser mathématiquement, et donc numériquement, une texture, deux types d'analyse peuvent être dégagés : l'analyse statistique et l'analyse




FIGURE 3.5 – Notion d'échelle d'observation d'une texture : une brique est composée d'une micro-texture isotrope et les briques du mur forment une macro-texture anisotrope.

fréquentielle de l'image. Ces deux types d'analyse sont détaillés ci-après (*cf.* parties 3.2.1 et 3.2.2). Contrairement aux indices spectraux calculés à partir d'un seul pixel, les attributs de texture nécessitent de prendre en compte les pixels contenus dans le voisinage du pixel étudié, la taille de ce voisinage est liée à l'échelle d'analyse souhaitée. Ainsi, les textures sont généralement calculées sur une vignette de taille constante, centrée autour d'un pixel central.

### 3.2.1 Analyse statistique

Trois types d'analyses statistiques peuvent être menées sur une vignette d'image et seront détaillées ici : l'étude de l'occurrence des pixels de la vignette, de la co-occurrence de ces pixels, et de la complexité de la vignette.

#### Attributs d'occurrence

En mathématique, les mesures statistiques permettent d'étudier le comportement d'une liste de variables aléatoires. Appliquées aux images, elles permettent de mesurer le comportement de l'image dans un voisinage de chaque pixel, une vignette. Les attributs (pixels) d'une vignette sont considérés comme les valeurs d'une variable aléatoire. Ainsi, les mesures statistiques classiques peuvent être utilisées, par exemple les moments de différents ordres : la moyenne ( $\bar{m}$ ), la variance ( $\sigma$ ), le coefficient de dissymétrie (skewness :  $\gamma$ ) et le coefficient d'aplatissement (kurtosis :  $\beta$ ) (Figure 3.6) :

$$\begin{aligned}
\bar{m} &= E[I] = \frac{1}{\#(V)} \sum_{(x,y \in V^2)} I(x,y), \\
\sigma &= \sqrt{E[I - \bar{m}]^2}, \\
\gamma &= E\left[\left(\frac{I - \bar{m}}{\sigma}\right)^3\right], \\
\beta &= \frac{E[(I - \bar{m})^4]}{(E[(I - \bar{m})^2])^2},
\end{aligned}$$

où,  $I$  est l'image,  $V$  la vignette considérée,  $\#(V)$  le cardinal de la vignette (*i.e.*, le nombre de pixels de la vignette), et  $E$  l'espérance calculée sur la vignette  $V$ .

Ces attributs sont appelés attributs d'occurrence, car ils sont calculés directement sur les valeurs d'un attribut associé à chaque pixel de la vignette autour du pixel étudié.

De manière analogue, des histogrammes peuvent être calculés sur les vignettes de l'image, afin de décrire la texture de l'image [Lowitz, 1983]. van de Sande et al. [2010] proposent de calculer ces histogrammes sur différents espaces colorimétriques pour la reconnaissance d'objets (Figure 3.7). Par ailleurs, de tels histogrammes peuvent être calculés sur des attributs plus complexes [Vakili et Veksler, 2010], tels que les gradients orientés [Dalal et Triggs, 2005] ou les contours orientés [Levi et Weiss, 2004]. Issus de la communauté de la vision par ordinateur, ces approches commencent à être utilisés également dans le domaine de la télédétection [Zhang et al., 2014].

### Attributs de co-occurrence

D'autre part, une seconde famille d'attributs de texture statistique peut être dégagée. Il s'agit des attributs de co-occurrence. Ces derniers prennent en compte l'information spatiale entre les couples de pixels d'une vignette de l'image. Ces attributs sont fondés sur la matrice de co-occurrence (Grey-Level Co-occurrence Matrix (GLCM)) introduite par Haralick et al. [1973]. La matrice de co-occurrence d'une vignette  $V$  d'une image  $I$ , comprenant  $L$  niveaux de gris, pour la direction ( $\theta$ ) et de la distance ( $d$ ) donnée, correspondant au décalage  $(\Delta x, \Delta y)$ , est une matrice carrée de taille  $L \times L$  définie par :

$$P_{\Delta x, \Delta y}(i, j) = \sum_{(p, q \in V^2)} \begin{cases} 1, & \text{si } I(p, q) = i \text{ et } I(p + \Delta x, q + \Delta y) = j \\ 0, & \text{sinon.} \end{cases}$$

où  $(i, j)$  sont les niveaux de gris de l'image  $I$  et  $(p, q)$  les indices spatiaux des pixels dans l'image  $I$ . Cette matrice est ensuite normalisée par le nombre de paires de pixels considéré ( $R$ ) :  $p(i, j) = P(i, j)/R$ . Enfin, sont définis la






FIGURE 3.6 – Attributs statistiques calculés sur l'extrait d'image Pléiades de la Figure 3.2, suivant la taille du voisinage choisie (de haut en bas : 2, 4 et 8 pixels), de gauche à droite : la moyenne, la variance et le coefficient de dissymétrie (skewness).




FIGURE 3.7 – Attributs extraits d'une image Pléiades : les 3 premières composantes de l'ACP calculées sur différents éléments : de gauche à droite, en haut le moment colorimétrique, et les histogrammes sur des vignettes locales dans les espaces des couleurs opposées et HSV ; en bas les histogrammes locaux dans les espaces RVB, RVB normalisé ( $R+V+B=1$ ) et RVB normalisé statistiquement sur l'image (moyenne nulle et écart-type de 1).

moyenne  $\mu_t$  et l'écart-type  $\sigma_t$  de la somme des colonnes, la moyenne pondérée  $\mu = \sum_{i,j} i \cdot p(i, j) = \sum_{i,j} j \cdot p(i, j)$  et la variance pondérée  $\sigma = \sum_{i,j} (i - \mu)^2 p(i, j)$ . La matrice de co-occurrence permet de dériver huit indices de texture présentés dans le Tableau 3.1.

Énergie	$f_1 = \sum_{i,j} p(i, j)^2$
Entropie	$f_2 = - \sum_{i,j} p(i, j) \log_2 p(i, j)$ et 0 si $p(i, j) = 0$
Corrélation	$f_3 = \sum_{i,j} \frac{(i-\mu)(j-\mu)p(i,j)}{\sigma^2}$
Moment de différence	$f_4 = \sum_{i,j} \frac{1}{1+(i-j)^2} p(i, j)$
Inertie (Contraste)	$f_5 = \sum_{i,j} (i - j)^2 p(i, j)$
Cluster shade	$f_6 = \sum_{i,j} ((i - \mu) + (j - \mu))^3 p(i, j)$
Cluster prominence	$f_7 = \sum_{i,j} ((i - \mu) + (j - \mu))^4 p(i, j)$
Corrélation d'Haralick	$f_8 = \frac{\sum_{i,j} (i,j)p(i,j) - \mu_t^2}{\sigma_t}$

Tableau 3.1 – Les huit canaux d'Haralick existants.

Ces indices dépendent toujours de la direction ( $\theta$ ) et la distance ( $d$ ) choisies, et donc du décalage ( $\Delta x, \Delta y$ ) associé. Ils peuvent être rendus isotropiques en les moyennant sur plusieurs directions. Sur l'image étudiée, la direction n'a pas une grande influence sur les différents indices calculés (Figure 3.8) et la dimension de la matrice est souvent réduite en quantifiant l'image en un nombre limité de niveaux.

Les indices d'Haralick sont très répandus dans la littérature, autant dans le domaine de l'image médicale [Thibault et al., 2009; Mole et Ganesan, 2010; Sabu et Ponraj, 2012], avec des applications variées comme la classification de noyaux de cellules ou la détection de cancer, que dans le domaine de la télédétection. Dans ce dernier, on peut citer les travaux de Puissant [2003] sur l'extraction d'objets urbains à partir d'images THR et ceux de Le Bris [2012] qui utilisent ces indices pour la caractérisation des vignes sur des images aériennes (à 0,50 m de résolution). Par ailleurs, Hussain et al. [2013] évoquent l'utilisation des indices d'Haralick pour la détection de changements entre deux images.

De plus, d'autres indices de texture utilisent également les matrices de co-occurrence. C'est le cas, par exemple, de l'attribut anisotropique Pantex, qui permet de distinguer les zones bâties des zones non-bâties [Pesaresi et al., 2008]. Enfin, la matrice de co-occurrence peut être remplacée par le semi-variogramme introduit dans [Clark, 1979] (Équation 3.1), afin d'améliorer les classifications, en particulier sur les images RADAR [Carr et de Miranda, 1998].

$$Var(\Delta x, \Delta y) = \frac{1}{\#(V)} \sum_{(x,y) \in V^2} \|I(x, y) - I(x + \Delta x, y + \Delta y)\|, \quad (3.1)$$

où  $V$  est la vignette sur laquelle est calculé le semi-variogramme.






FIGURE 3.8 – Attributs d’Haralick calculés sur l’extrait d’image Pléiades de la Figure 3.2 : chaque colonne représente une direction (verticale, horizontale et diagonale) avec une distance de 1 pixel et chaque ligne un attribut (énergie, entropie et contraste, respectivement).



## Attributs de complexité

Baillard [1997] propose deux indices permettant de quantifier la notion de complexité de la structure de l'image et ainsi de caractériser la texture d'une image. À partir d'un masque d'image  $R$ , défini sous la forme d'une fonction gaussienne centrée sur le pixel courant et de largeur modélisée par un écart-type  $\sigma$  de valeur 10, le premier indice  $C$  est défini comme le ratio suivant :

$$\begin{aligned} C &= \frac{N_v}{N}, \\ \text{avec :} \\ N &= \sum_z R(z), \\ N_v &= \sum_{z \in S} R(z). \end{aligned}$$

où  $S = \{z : M(z) > c\}$ , est l'ensemble des pixels à fort gradient,  $M$  est le module du gradient de l'image et  $c$  un seuil, généralement fixé à 6.

Par la suite, on considère l'histogramme  $H$  de l'argument  $\theta$  du gradient de l'image, défini par rapport à  $K$  intervalles réguliers du domaine angulaire  $[0, \pi]$  :

$$\begin{aligned} S(i) &= \#\{z \in S : i\pi/K \leq \theta(z) < (i+1)\pi/K\}, \\ H(i) &= \frac{1}{N_v} \sum_{z \in S(i)} R(z). \end{aligned}$$

L'entropie  $E$  est alors définie de la manière suivante :

$$E = - \sum_{i \in I} H(i) \log_2 H(i).$$

La Figure 3.9 montre le calcul de ces deux indices sur un extrait d'image Pléiades. Ces indices sont très pertinents sur des images aériennes (0,5 m de résolution) pour la classification de classes d'occupation du sol [Trias-Sanz, 2006a], ou encore pour l'identification des zones de forêt [Le Bris et al., 2013].

### 3.2.2 Analyse fréquentielle

Le deuxième type d'approches pour la description des textures repose sur l'analyse fréquentielle de l'image. Ces méthodes proviennent du traitement du signal et elles reposent sur la décomposition du signal (ici l'image) en une somme de fonctions, constituant la base de la décomposition. Ces fonctions sont sinusoïdales dans le cas de la transformée de Fourier [Fourier, 1822]. Cependant, d'autres bases de fonctions ont été introduites, donnant lieu à un ensemble de décompositions, dites en ondelettes [Mallat, 1989]. De plus, l'information extraite est non localisée dans le cas de la transformée de Fourier, mais devient localisée avec la transformée de Fourier locale ou les transformées en ondelettes,




FIGURE 3.9 – Attributs de complexité calculés sur l'extrait d'image Pléiades de la Figure 3.2 : à gauche le ratio des pixels à fort gradient ( $C$ ) et à droite l'entropie ( $E$ ).

permettant une analyse par sous-région des images. La transformée de Fourier et différentes décompositions en ondelettes, ainsi que leurs applications sont détaillées dans les deux sous-sections suivantes, puis un inventaire des autres méthodes existantes est dressé dans la dernière sous-section.

### Transformée de Fourier

La transformée de Fourier est une extension des travaux de Fourier sur la décomposition en série des fonctions périodiques, pour l'étude de la propagation de la chaleur [Fourier, 1822]. Elle est définie comme suit :

$$\hat{f}(u, v) = \int_{-\infty}^{+\infty} \int_{-\infty}^{+\infty} f(x, y) \cdot e^{-i(ux+vy)} dx dy.$$

Cette définition dans le domaine continu est facilement transformable dans le domaine discret et une implémentation rapide existe (Fast Fourier Transform) [Walker, 1996] permettant de l'appliquer facilement sur des images de télédétection (Figure 3.10). La transformée de Fourier d'une image donne ainsi une information sur l'orientation et la périodicité de la texture de celle-ci. Cependant cette information n'est pas localisée [Lienou, 2009]. Dans le domaine de la télédétection, la transformée de Fourier est utilisée, par exemple, pour la détection et la discrimination d'objets à texture régulière comme les vignes ou les vergers [Delenne et al., 2006, 2010; Le Bris, 2012].

Par ailleurs, la transformée de Fourier locale, en anglais Short-Time Fourier Transform (STFT) rajoute une information de la localisation en calculant la transformée de Fourier sur un voisinage de chaque pixel  $(x_0, y_0)$  de l'image :

$$\hat{f}_{(x_0, y_0)}(u, v) = \int_{-\infty}^{+\infty} \int_{-\infty}^{+\infty} f(x, y) \cdot w(x - x_0, y - y_0) \cdot e^{-i(u(x-x_0)+v(y-y_0))} dx dy.$$

où  $w$  est une fonction valant 1 sur un voisinage de l'origine et 0 ailleurs.

L'ajout de cette information spatiale permet diverses applications en télédétection, comme la détection et la caractérisation de végétation [He et al., 2012].




FIGURE 3.10 – Module de la transformée de Fourier de l'extrait d'image Pléiades de la Figure 3.2.

## Ondelettes

Les transformées en ondelettes sont une généralisation de la transformée de Fourier locale vue dans le paragraphe précédent. La différence réside dans l'utilisation d'une base différente de fonctions, appelées ondelettes. Ces ondelettes ont la particularité de pouvoir être modulées non seulement par la fréquence, mais aussi par la largeur de l'enveloppe. Cette seconde modulation permet une analyse fréquentielle localisée sur un voisinage plus ou moins étendu et permet une description plus fine de la texture d'une image [Zhu et Yang, 1998; He et al., 2012].

Un nombre important d'ondelettes existent et sont utilisées en télédétection [Ranchin et Wald, 1993], comme les ondelettes de Daubechies, de Haar ou de Gabor. Ces deux dernières, parmi les plus répandues, seront détaillées ci-après.

**Haar** Les ondelettes de Haar sont les premières ondelettes à avoir été utilisées. Elles reposent sur la fonction  $\phi$  introduite par A. Haar en 1909 et définie comme suit :

$$\phi(x) = \begin{cases} 1 & 0 \leq x < 1/2, \\ -1 & 1/2 \leq x < 1, \\ 0 & \text{sinon.} \end{cases}$$

Dans le cas d'une image, la transformée de Haar d'une image de taille (N,N) fournit 4 images de taille (N/2,N/2) : une image approximée et trois images

de détails (horizontaux, verticaux et diagonaux). L'application successive de la transformée de Haar sur l'image approximée de l'étape précédente permet une analyse multi-échelle de la texture de l'image (Figure 3.11). Les ondelettes de Haar sont utilisées principalement pour la compression d'image [Mulcahy, 1997; Talukder et Harada, 2010] et plus anecdotiquement pour la classification d'éléments texturés [Singh et al., 2012], mais sont en pratique assez peu utilisées en télédétection.




FIGURE 3.11 – Filtres de Haar appliqués sur l'extrait d'image Pléiades de la Figure 3.2 : à chaque niveau de décomposition on voit les images de détails horizontaux (en haut à droite), verticaux (en bas à gauche) et diagonaux (en bas à droite) ainsi que la décomposition de l'image approximée en haut à gauche. La dernière image, en haut à gauche, correspond à l'image approximée de la dernière décomposition.

**Gabor** Les ondelettes de Gabor sont des fonctions sinusoides complexes modulées par une fonction gaussienne :

$$g(x) = \exp\left(2j\pi u_0 x + \phi\right) \cdot \exp\left(-\frac{(x - x_0)^2}{2\sigma^2}\right).$$

Les paramètres  $u_0$ ,  $\phi$ ,  $x_0$  et  $\sigma_x$  permettent de régler, respectivement, la fréquence spatiale et le déphasage de la fonction sinusoidale, ainsi que l'origine et la largeur de la fonction de modulation. Dans le domaine du traitement d'images, on utilise les parties réelle et imaginaire de ce filtre adapté en deux dimensions :

$$G_1(x, y) = \cos(ax + by) \cdot \exp\left(-\frac{x^2 + y^2}{2\sigma^2}\right) \quad (3.2)$$

$$G_2(x, y) = \sin(ax + by) \cdot \exp\left(-\frac{x^2 + y^2}{2\sigma^2}\right) \quad (3.3)$$

où les paramètres  $a$  et  $b$  permettent de régler la fréquence et l'orientation de l'ondelette, et  $\sigma$  la largeur de la fonction de modulation. Un exemple d'ondelette est visible sur la Figure 3.12 et son application à une image Pléiades avec différents paramètres d'orientation et de largeur de modulation est présentée sur la Figure 3.13.




FIGURE 3.12 – Vue 3D de la partie réelle (à gauche) et imaginaire (à droite) d'une ondelette de Gabor ( $a = 0$ ,  $b = 1$  et  $\sigma = 1$ ).




FIGURE 3.13 – Filtres de Gabor appliqués sur l'extrait d'image Pléiades de la Figure 3.2 : chaque colonne correspond à une orientation différente (de gauche à droite :  $0$ ,  $\pi/4$  et  $\pi/2$ ) et chaque ligne à un  $\sigma$  différent (de haut en bas :  $0,05$ ;  $0,025$ ).



Les filtres de Gabor sont utilisés en vision par ordinateur pour la segmentation de texture [Dunn et al., 1994; Dunn et Higgins, 1995]. Dans le même domaine Grigorescu et al. [2002] utilisent l'énergie de Gabor (définie comme la norme euclidienne des filtres symétrique et anti-symétrique). En télédétection, les ondelettes de Gabor sont utilisées pour discriminer les éléments texturés : par exemple Reis et Taşdemir [2011] les utilisent pour discriminer les vergers des autres types de régions boisées sur des images à THR Quickbird (0,61 m de résolution).

## Autres analyses fréquentielles

Il existe dans la littérature un nombre important d'autres méthodes d'analyse fréquentielle de la texture d'une image. On peut citer par exemple les motifs binaires locaux, en anglais *Local Binary Pattern* (LBP), qui sont utilisés en vision par ordinateur pour la détection d'objet comme les visages [Louis et Plataniotis, 2011], ou dans le domaine du traitement d'images médicales comme descripteur de texture pour la détection de cellules cancéreuses [Sabu et Ponraj, 2012]. En télédétection, les LBP sont utilisés pour la segmentation d'images [Guo et al., 2005] ou encore pour la classification d'images satellite haute résolution (HR) [Trias-Sanz, 2006a].

Par ailleurs, les SIFT (*Scale Invariant Feature Transform*), introduits par Lowe [2004] pour la détection de points d'intérêt en vue de la recherche de points d'appariements, fournissent également une information de texture aux alentours de ces points. Cependant, le descripteur SIFT - un vecteur de 128 composantes - peut être calculé sur chaque pixel de l'image : on parle alors de SIFT dense. D'après Le Bris [2012], les trois premières composantes de l'ACP de l'image de SIFT dense (Figure 3.14) permettent de discriminer correctement les éléments texturés comme les vignes sur des ortho-images aériennes à 0,5 m de résolution.




FIGURE 3.14 – Différents attributs de texture calculés sur l'extrait d'image Pléiades de la Figure 3.2 : à gauche les *Local Binary Pattern* (LBP), à droite les trois premières composantes de l'ACP d'une image de SIFT dense.

### 3.3 Attributs géométriques et notion d'objet

Le troisième type d'information pouvant être extrait d'une image est la géométrie des objets qui la composent. Cette information peut être extraite en étudiant les lignes de directions (3.3.1), en utilisant des opérateurs issus de la morphologie mathématique (3.3.2) ou par extraction de régions homogènes - appelées objets (3.3.3). Une autre notion d'attributs géométriques consiste à extraire des objets structurés (lignes, rectangles, cercles, ...) afin de construire des attributs haut niveau, mais ne sera pas abordée ici.

#### 3.3.1 Attributs de forme

Les Structural Feature Set (SFS), introduits dans [Huang et al., 2007], sont une extension de l'indice de forme PSI (*Pixel Shape Index*) proposé dans Zhang et al. [2006]. Les SFS permettent d'extraire des informations statistiques dans l'histogramme des extensions des lignes de direction de l'image. L'extension  $d$  d'une ligne dans une direction donnée est définie comme la mesure d'un ensemble de pixels alignés sur un pixel central  $c$  et dont la différence des niveaux de gris est faible (inférieure à un seuil donné). Ainsi, différents attributs peuvent être déduits de cet histogramme  $\{d_i\}_{i \in [1, D]}$ , tels que la longueur ( $l$ ) ou la largeur ( $w$ ) définies comme suit :

$$\begin{aligned} l(c) &= \max_{i \in [1, D]} (d_i(c)), \\ w(c) &= \min_{i \in [1, D]} (d_i(c)). \end{aligned}$$

Les autres attributs pouvant être extraits de cet histogramme (PSI, W-Mean, Ratio et SD) sont détaillés dans l'article d'origine et sont illustrés sur la Figure 3.15. Ces attributs sont très performants pour séparer les routes des bâtiments, qui sont généralement difficiles à discerner avec des attributs spectraux [Huang et al., 2007; Huang et Zhang, 2013].

#### 3.3.2 Attributs morphologiques

Les attributs morphologiques permettent de prendre en compte la géométrie des objets composant l'image sans pour autant nécessiter une segmentation préalable (*cf.* sous-section 3.3.3). D'abord utilisés pour la détection d'objet spécifique, comme les bâtiments [Lefèvre et al., 2007], les opérateurs morphologiques sont utilisés pour générer des profils morphologiques et des profils d'attributs permettant une description multi-échelle d'une image.

Les attributs morphologiques reposent sur les opérateurs mathématiques d'ouverture et de fermeture, qui sont définis respectivement comme une érosion suivie d'une dilatation (resp. une dilatation suivie d'une érosion), ainsi que sur




FIGURE 3.15 – Attributs SFS extraits d’une image Pléiades, sur la première ligne : la longueur ( $l$ ), la largeur ( $w$ ), PSI, et sur la seconde ligne : W-Mean, Ratio, SD.

le principe de reconstruction géodésique (succession de dilatations à l’intérieur d’un masque jusqu’à idempotence).

L’application itérative d’ouvertures ou fermetures, reconstruction géodésique, permet de réaliser une décomposition multi-échelle de l’image. Cette décomposition proposée dans [Pesaresi et Benediktsson \[2001\]](#) est appelée profil morphologique (PM).

[Dalla Mura et al. \[2010\]](#) proposent une extension des PMs, nommée profils d’attributs (PAs), en ajoutant une étape de filtrage des régions par différents attributs. Les PAs permettent ainsi de modéliser plus finement l’information spatiale en utilisant des filtres utilisant différents attributs comme l’aire, la longueur de la diagonale de la région, l’écart-type ou le moment d’inertie des pixels de cette dernière.

En pratique, les PAs sont composés de deux profils, un profil d’amincissement (supprimant les zones claires de l’image) et un profil d’épaississement (supprimant les zones foncées de l’image). Ces deux profils sont obtenus par applications successives de filtres par attributs en faisant varier les seuils (par exemple, en filtrant les zones d’aire de plus en plus grande). La Figure 3.16 montre différentes images extraites de quatre PAs, utilisant autant d’attributs différents, de haut en bas : par aire de la région, par longueur de la diagonale de la région, par le moment d’inertie des pixels de la région et par l’écart-type des



pixels de la région. Pour chaque PA, *i.e.*, chaque ligne d'images, les deux images de gauche correspondent aux profils d'épaississement avec un seuil décroissant et les deux images de droite aux profils d'amincissement avec un seuil croissant.

Enfin, [Lv et al. \[2014\]](#) adaptent les PAs aux images THR en introduisant l'utilisation conjointe de différents éléments structurants et montrent que les PAs améliorent la précision des classifications sur ce type de données.




FIGURE 3.16 – Profils d'attributs morphologiques calculés sur différents attributs, (les valeurs seuils des attributs sont indiquées entre parenthèses), 1<sup>re</sup> ligne : aire (100 / 1 000) ; 2<sup>e</sup> ligne : diagonal (10 / 50) ; 3<sup>e</sup> ligne : inertie (0,2 / 0,4) et 4<sup>e</sup> ligne écart-type (20 / 40). Les deux images de gauche correspondent au filtre d'épaississement et celles de droite à celui d'amincissement.

### 3.3.3 Notion d'objet (ou région)

Une approche de plus en plus utilisée, avec l'augmentation de la taille des images, est l'utilisation de super-pixels (ou objets, régions) correspondant à des zones homogènes sur l'image. En effet, l'utilisation d'objets permet de réduire le nombre d'éléments à classifier. Ces objets sont extraits de l'image par des tech-

niques dites de segmentation ou de classification non-supervisée (*cf.* chapitre 5).

Un très grand nombre de méthodes de segmentation d'image existe dans la littérature [Walter, 2004; Blaschke, 2010; Lefebvre et al., 2008; Zhou et al., 2008; Vakili et Veksler, 2010] et plusieurs états de l'art sur le sujet ont été réalisés [Pal et Pal, 1993; Dey et al., 2010] et plus récemment [Sonka et al., 2014]. Ces méthodes peuvent être classées en trois grandes catégories, les méthodes de seuillages, les méthodes fondées sur les contours et celles fondées sur les régions (*cf.* Figure 3.17). On peut citer par exemple, la méthode de seuillage d'Otsu [Otsu, 1979], les Lignes de Partage des Eaux [Beucher, 1992] ou encore la méthode *Mean Shift* [Comaniciu et Meer, 1999]. Par ailleurs, certaines méthodes permettent de réaliser une segmentation supervisée, permettant d'adapter la segmentation aux thèmes d'intérêts [Derivaux et al., 2010].

Une fois la segmentation réalisée, un certain nombre d'attributs est calculé au niveau de chacun des objets. Ces attributs peuvent être liés à la forme (aire, longueur, largeur, compacité, ...) de l'objet lui-même, ce sont des attributs purement géométriques [Loncaric, 1998; Zhang et Lu, 2004; Lienou, 2009].

L'ensemble des attributs spectraux et de texture vus dans ce chapitre peuvent être étudiés au niveau de l'objet. Dans le cas des attributs spectraux, une étude statistique peut être menée (*e.g.*, moyenne, écart-type). Pour les attributs de texture, le voisinage d'étude est remplacé par l'objet lui-même. Ceci permet d'étudier la texture sur une zone homogène et donc d'obtenir des mesures de texture plus précises. Enfin, la relation spatiale entre ces objets peut être utilisée afin de permettre la classification de classe de mélange, c'est le cas par exemple de l'approche par sac-de-mots proposée par Lienou [2009]. Les approches orientées-objets sont de plus en plus utilisées dans la littérature [Blaschke et al., 2014] et les nouvelles approches cherchent à prendre en compte les relations de voisinage, des informations multi-échelles, ainsi que les relations sémantiques (ontologies) entre les thèmes de la nomenclature utilisée [Arvor et al., 2013].



FIGURE 3.17 – Segmentation d'images, de gauche à droite, par Ligne de Partage des Eaux, *Mean Shift* (segments entourés) et seuillage multiple par la méthode d'Otsu (une couleur par segment).

## 3.4 Conclusion

Nous avons pu voir dans ce chapitre qu'un très grand nombre d'attributs spectraux, de texture et géométriques, peut être extrait des images de télédétection. Nous avons pu voir également que deux niveaux d'analyse peuvent être discernés, un premier niveau au pixel (éventuellement sur son voisinage) et un deuxième niveau à celui de l'objet (issu d'une méthode de segmentation).

Cependant, bien que très intéressantes, les méthodes fondées sur la segmentation peuvent manquer de précision, en particulier alors que les objets à segmenter sont très variés. Par exemple, une vigne sera in-homogène spectralement mais sa texture sera homogène, alors qu'un champ sera beaucoup plus homogène spectralement. Les algorithmes de segmentation ne permettent pas facilement de s'adapter aux différents thèmes existant dans les BD d'OCS. Ainsi, nous avons décidé de réaliser des classifications pixellaires pour ne pas être affecté par ce problème.

Par ailleurs, ces attributs peuvent être extraits facilement en utilisant différents outils ou bibliothèques comme StairVision Library [Gould et al., 2011], VLFeat [Vedaldi et Fulkerson, 2010], colorDescriptor [van de Sande et al., 2010] ou la très complète boîte à outils open-source du CNES Orfeo Toolbox (OTB) [Inglada et Christophe, 2009].

Enfin, un trop grand nombre d'attributs nuit généralement à une bonne qualité de classification : c'est le phénomène appelé malédiction de la dimension [Bellman, 1961]. Ainsi une étape de sélection d'attributs est nécessaire avant de réaliser la classification. Cette étape sera l'objet du chapitre suivant.



# Réduction de dimension et sélection d'attributs

---

## Sommaire

---

<b>5.1</b>	<b>Classification non-supervisée . . . . .</b>	<b>62</b>
<b>5.2</b>	<b>Classification supervisée . . . . .</b>	<b>64</b>
5.2.1	Choix d'un ensemble d'apprentissage . . . . .	64
5.2.2	Algorithmes de classification supervisée . . . . .	65
<b>5.3</b>	<b>Ensemble et fusion de classifieurs . . . . .</b>	<b>71</b>
5.3.1	Ensemble de classifieurs . . . . .	71
5.3.2	Fusion de classifieurs . . . . .	72
<b>5.4</b>	<b>Évaluation d'une classification . . . . .</b>	<b>73</b>
<b>5.5</b>	<b>Conclusion . . . . .</b>	<b>75</b>

---

Les méthodes de sélection d'attributs cherchent à faire face à malédiction de la dimension [Bellman, 1961]. En effet, le nombre toujours croissant d'attributs de classification (*cf.* chapitre 3) met en défaut les algorithmes de classification classiques (diminution des taux de bonne classification et augmentation des temps de calcul avec l'augmentation du nombre d'attributs). Ainsi, le but de ces méthodes est de réduire la dimension de l'espace des attributs, afin de faciliter le travail de classification.

Deux types d'approches peuvent être discernées et seront détaillées dans ce chapitre. D'une part, les approches fondées sur la transformation des données, généralement par projection dans un espace de dimension inférieure (section 4.1), et d'autre part les approches de sélection d'attributs, cherchant un sous-ensemble optimal d'attributs (section 4.2).

## 4.1 Réduction de dimension

Les méthodes de réduction de dimension cherchent à extraire de l'espace des attributs un espace de dimension inférieure en maximisant un critère de séparation des classes (cas supervisé) ou un critère de séparation des données (cas non-supervisé). Deux catégories de méthodes peuvent être distinguées et seront détaillées dans cette section : les méthodes linéaires (sous-section 4.1.1) et les non-linéaires (sous-section 4.1.2).

### 4.1.1 Méthodes linéaires

Parmi les méthodes linéaires, l'Analyse en Composantes Principales (ACP) est une méthode non-supervisée cherchant à maximiser la variance entre les données [Jolliffe, 2005]. Cette maximisation est obtenue par une transformation orthogonale linéaire, permettant de regrouper la majeure partie de l'information sur les composantes correspondant aux valeurs propres les plus fortes (Figure 4.1). L'ACP est efficace dans le cas de données linéairement séparables, dans le cas contraire la méthode est peu efficace. Elle est également très sensible au bruit dans les données [Bishop, 2006]. Pour contrer ce problème, plusieurs auteurs proposent de réduire le bruit de l'image avant d'appliquer l'ACP : par exemple [Green et Berman, 1988] avec la transformation *Maximum Noise Fraction* et [Lee et al., 1990] avec l'ACP à bruit ajusté, illustrée sur la Figure 4.1.

Par ailleurs, d'autres méthodes utilisent différents critères de séparation de données afin d'améliorer les résultats obtenus. Par exemple, la méthode d'Analyse en Composantes Indépendantes (ICA), proposée par Jutten et Herault [1991], maximise l'indépendance statistique entre les données, et la méthode Maximum Autocorrelation Factor (MAF) maximise l'auto-corrélation spatiale [Larsen, 2002] (*cf.* Figure 4.2).

Toujours dans les méthodes non-supervisées, la méthode de positionnement multi-dimensionnel cherche à plonger les observations dans un espace à plus



faible dimension en préservant la matrice de distances, ou de similarités, point à point entre ces observations [Messick et Abelson, 1956].

Dans le cas supervisé, l'Analyse Linéaire Discriminante (ALD) cherche à maximiser l'homogénéité des classes et la variance inter-classes. Cette méthode aussi connue sous le nom d'analyse de Fisher [Fisher, 1936] est détaillée dans [Lebart et al., 1997].



FIGURE 4.1 – Résultats d'une ACP (en haut) et de sa variante à bruit ajusté réalisée sur une image Pléiades (RVB-IR) de la Figure 3.2 : les trois premières composantes de l'ACP correspondant aux valeurs propres (par ordre décroissant de gauche à droite).

#### 4.1.2 Méthodes non-linéaires

Les méthodes non-linéaires sont généralement adaptées des méthodes linéaires présentée précédemment en ajoutant un noyau afin de basculer dans un espace différent [Gómez-Chova et al., 2011]. La notion de noyau est très utilisée en apprentissage automatique (*machine learning*) [Schölkopf et Smola, 2002] et on la retrouvera plus tard dans les méthodes de classification (section 5.2.2). Par exemple, Schölkopf et al. [1998] proposent l'utilisation de tels noyaux pour l'amélioration de l'ACP.

De manière analogue, l'analyse discriminante de Fisher par noyau (en anglais Kernel Fisher Discriminant Analysis) est une adaptation de l'ALD, proposée par Mika et al. [2001]. L'introduction de noyaux dans l'ALD permet ainsi de traiter



FIGURE 4.2 – ICA (en haut) et MAF (en bas) réalisées sur une image Pléiades (RVB-IR) de la Figure 3.2 : les composantes de l’ACP correspondant aux valeurs propres (par ordre décroissant de gauche à droite).

les cas où les classes étudiées ne sont pas séparables linéairement dans l’espace des attributs.

Par ailleurs, l’algorithme ISOMAP [Tenenbaum et al., 2000] cherche une variété non-linéaire contenant les données en minimisant, comme la méthode de positionnement multidimensionnel, la matrice de distance (ou de similarité) point à point.

## 4.2 Sélection d’attributs

Les méthodes de sélection d’attributs cherchent un sous-ensemble optimal d’attributs sans modifier ces derniers, contrairement aux méthodes précédentes. Cette recherche est caractérisée par une procédure d’exploration des sous-ensembles d’attributs (4.2.1) et un critère d’évaluation de ces sous-ensembles (4.2.2).

Par ailleurs, ces différentes méthodes peuvent être supervisées (nécessite un apprentissage des classes existantes) ou non supervisées. Ainsi, les premières chercheront à trouver les attributs qui séparent au mieux les classes existantes, alors que les secondes chercheront un sous-ensemble optimal d’attributs pour regrouper les données en classes le plus homogènes possibles (mesure de pureté) tout en maximisant la distance inter-classes (mesure de séparabilité). Les méthodes non-supervisées sont apparentées aux algorithmes de *clusterisation*.



D'ailleurs, certaines de ces méthodes utilisent de tels algorithmes, c'est le cas en particulier des kMeans-FS (FS : *Feature Selection*) qui sont fondés sur l'algorithme des k-Moyennes, ou des SCV-FS utilisant l'algorithme *Support Vector Clustering* [Campedel et al., 2004].

Une présentation de l'utilisation de ces méthodes dans le domaine de la télédétection est réalisée dans la sous-section 4.2.3.

#### 4.2.1 Méthodes d'exploration

Différentes méthodes d'exploration existent dans la littérature. La première est l'exploration exhaustive de l'ensemble des sous-ensembles d'attributs. Cette solution n'est envisageable uniquement lorsque le nombre d'attributs est faible, car la combinatoire augmente de manière exponentielle et le problème devient rapidement non-solvable par un ordinateur classique. Les autres méthodes de la littérature proposent donc une exploration non-exhaustive des sous-ensembles d'attributs. On peut classer les méthodes non-exhaustives en trois types : les méthodes heuristiques, les méthodes aléatoires et les méthodes optimales.

Dans le premier cas, l'insertion de règles heuristiques permet de converger rapidement vers un sous-ensemble optimal d'attributs. Il peut s'agir d'approches ascendantes (forward) qui ajoutent des attributs petit à petit, appelée *Sequential Forward Selection* (SFS) [Marill et Green, 1963] ou d'approches descendantes (backward) partant de l'ensemble complet et supprimant des attributs, appelée *Sequential Backward Selection* (SBS) [Whitney, 1971]. Kittler [1978] propose une généralisation de ces méthodes, nommée *Plus-l-Minus-r*, par l'ajout ou la suppression des attributs par sous-ensembles pour améliorer la rapidité de convergence. Enfin, les deux méthodes ascendantes et descendantes peuvent être combinées pour améliorer le processus, c'est le cas par exemple des méthodes : *Sequential Floating Forward Selection* (SFFS) et *Sequential Floating Backward Selection* (SFBS), ou les paramètres d'inclusion et d'exclusion d'attributs varient au cours des itérations [Pudil et al., 1994].

Dans le second cas, la recherche est effectuée aléatoirement. Encore une fois, deux types de méthodes existent : les méthodes aléatoires uniformes et les méthodes aléatoires pondérées. L'algorithme *Las Vegas Wrapper* (LVW) est un exemple de méthode complètement aléatoire de génération de sous-ensembles d'attributs [Liu et Setiono, 1996]. À l'inverse, les algorithmes génétiques introduisent une pondération des sous-ensembles d'attributs en fonction de leurs importances [Goldberg, 1989; Holland, 1975]. Ces derniers améliorent donc la rapidité de convergence et la stabilité de la solution proposée.

Enfin, les méthodes optimales cherchent à contourner le problème de la dimension de recherche en proposant une stratégie de parcours menant à une solution optimale (contrairement aux méthodes heuristiques qui ne sont pas optimales). Par exemple, la méthode *Branch and Bound*, fondée sur l'utilisation de graphe, a été appliquée au problème de la sélection d'attributs par Narendra et Fukunaga [1977].

### 4.2.2 Méthodes d'évaluation

Outre la stratégie d'inspection, la méthode d'évaluation d'un seul ou d'un ensemble d'attributs permet de caractériser les différentes méthodes de sélection d'attributs. En pratique, trois grandes classes de méthodes sont différenciées dans la littérature et seront détaillées ci-après : les méthodes *filter*, *wrapper* et *embedded*.

Dans un premier temps, les méthodes dites *filter* cherchent à pondérer les attributs en fonction de leur capacité à rassembler les éléments d'une même classe et à séparer les éléments différents [John, 1997]. Ces méthodes sont indépendantes d'un classifieur et viennent donc comme une étape de filtrage préliminaire à l'étape de classification. La rapidité de la méthode d'évaluation est la force de ces méthodes, cependant leur indépendance à un algorithme de classification, et donc d'une application particulière, constitue leur faiblesse.

Le deuxième type de méthodes, appelé *wrapper*, pondère les attributs en fonction de leur pertinence par rapport à une prédiction [Kohavi et John, 1997]. Cette pondération est donc reliée à la performance d'un classifieur. Les données sont séparées en deux sous-ensembles, le premier servant à l'apprentissage, alors que le second sert à l'évaluation du classifieur. L'utilisation d'un classifieur est l'avantage de ces méthodes par rapport aux méthodes *filters* en terme de pertinence de choix des attributs. Cependant, elle induit un impact important en terme de temps de calcul.

Enfin, le dernier type regroupe les méthodes dites intégrées (*embedded*). Ici, la sélection des attributs est réalisée en même temps que l'apprentissage. L'avantage des méthodes intégrées est double, elles peuvent utiliser l'ensemble des données comme apprentissage et sont donc plus robuste, de plus, la réalisation de la sélection en même temps que l'apprentissage les rendent plus rapides que les méthodes *wrapper*. Différentes méthodes existent suivant l'algorithme de classification utilisé. Par exemple, les FA permettent de calculer l'importance de chaque attribut [Breiman, 2001] (*cf.* section 5.2.2). D'autres méthodes sont fondées sur le classifieur SVM. Par exemple, la méthode SVM-RFE (*Recursive Feature Elimination*) Guyon et al. [2002] supprime récursivement les attributs les moins pertinents, en utilisant leurs poids estimés par un SVM linéaire (*cf.* section 5.2.2). La méthode AROM (*Approximation of zero-norm Minimization*) [Weston et Elisseeff, 2003] introduit des contraintes supplémentaires sur les poids estimés par SVM.

### 4.2.3 Sélection d'attributs en télédétection

Les méthodes de sélection d'attributs sont largement utilisées dans le domaine de la télédétection qui fait face à la multiplication des données disponibles, à l'augmentation de leurs dimensions (augmentation de la résolution et des surfaces couvertes) et à la capacité à extraire de plus en plus d'informations pour une seule image.

Par exemple, les images hyperspectrales, qui peuvent comporter plusieurs centaines de bandes spectrales chacune, nécessitent l'utilisation de ce type de méthode. Dans ce domaine, Archibald et Fann [2007] proposent une méthode intégrée, fondée sur les SVM, qui permet de réaliser la sélection des bandes spectrales et la classification simultanément.

De leur côté, Chehata et al. [2009] proposent d'utiliser l'importance des attributs issue des Forêts Aléatoires (FA) (*cf.* section 5.2.2) pour sélectionner les attributs les plus pertinents pour la classification de nuages de points 3D LIDAR en milieu urbain. Les FA permettent ici de traiter efficacement de telles données malgré leurs dimensions importantes.

Enfin, Campedel et al. [2004] comparent différentes méthodes de sélection d'attributs provenant de données satellitaires HR (SPOT5), ici des attributs de texture de type Gabor et Haralick (*cf.* section 3.2). Ils concluent que, outre la bonne performance des méthodes non-supervisées, les méthodes intégrées utilisant les SVM donnent les meilleurs résultats.

### 4.3 Conclusion

Face à un nombre croissant d'attributs pour la classification, autant dans le domaine de l'apprentissage automatique en général, que dans celui de la télédétection en particulier, les méthodes de sélection d'attributs se sont fortement développées ces dernières années.

Ainsi, nous avons pu voir dans ce chapitre un aperçu des méthodes de réduction de dimension fondées soit sur la transformation des attributs, soit sur leur sélection. Cependant, afin de permettre le passage à l'échelle de notre méthode, nous souhaitions pouvoir ne calculer l'ensemble des attributs que sur un nombre restreint d'échantillons, puis ne calculer que les attributs sélectionnés sur l'ensemble de la zone. Ainsi, nous n'avons pas choisi d'utiliser les méthodes de transformation qui nécessitent d'avoir l'ensemble des attributs pour réaliser la projection dans l'espace réduit choisi.

Parmi les méthodes de sélection d'attributs, les méthodes intégrées semblent être un très bon compromis entre le temps de calculs et la qualité de la sélection. De plus, elles sont largement utilisées en télédétection (*cf.* sous-section 4.2.3). Ainsi, notre choix s'est porté sur ce type de méthodes, et en particulier sur l'importance des attributs des FA.

Par ailleurs, différentes bibliothèques de sélection d'attributs open-source ou gratuites sont disponibles. Dans le domaine de l'apprentissage automatique, on peut citer MLPY [Albanese et Visintainer, 2012], qui comporte différents algorithmes de classification, de sélection d'attributs et de réduction de dimension. La bibliothèque *Feature Selection Toolbox 3* (FST3) [Somol et al., 2010] implémente une variété importante de méthodes de sélection d'attributs de type *filter* et *wrapper*, avec différentes méthodes de recherche et de classification. Dans le domaine de la télédétection la bibliothèque OTB [Inglada et Christophe, 2009] contient dif-

férentes méthodes de réduction de dimension. Par ailleurs, elle intègre depuis peu la librairie OpenCV [Bradski et Kaehler, 2008] qui donne accès à différentes méthodes de classification et en particulier aux importances des attributs des FA, que nous utiliserons par la suite (*cf.* sous-section 7.1.2).

# Méthodes de classification et leurs utilisations en télédétection

---

## Sommaire

---

<b>6.1</b>	<b>Notations</b> . . . . .	<b>80</b>
6.1.1	Structure des bases de données géographiques . . . . .	80
6.1.2	Lien entre base de données et image . . . . .	82
6.1.3	Classification supervisée binaire . . . . .	83
<b>6.2</b>	<b>Inspection hiérarchique de la base de données géo-</b> <b>graphique</b> . . . . .	<b>84</b>
6.2.1	Niveau objet . . . . .	84
6.2.2	Niveau classe . . . . .	87
6.2.3	Niveau base de données . . . . .	87
<b>6.3</b>	<b>Validation théorique de la méthode</b> . . . . .	<b>89</b>
6.3.1	Présentation des données simulées . . . . .	89
6.3.2	Expérimentations . . . . .	90
<b>6.4</b>	<b>Conclusion</b> . . . . .	<b>93</b>

---

La classification consiste à regrouper un jeu de données en plusieurs sous-ensembles (appelés classes) selon un critère de similarité : les éléments de chaque sous-ensemble devant partager des caractéristiques communes (critère de similarité) alors que les éléments de deux sous-ensembles distincts devront, au contraire, être les moins semblables possible. Les méthodes de classification sont issues du domaine de l'apprentissage automatique (*machine learning* en anglais) et de la fouille de données (*data mining*). Ces méthodes sont très utilisées dans le domaine de la télédétection afin de classer les pixels (ou les régions) des images, en utilisant les attributs détaillés, tels que ceux dans le chapitre 3 [Camps-Valls et al., 2011; Escalante-Ramirez, 2012; Tupin et al., 2014b].

De manière générale, deux types de classifications sont distinguées dans la littérature. Si des exemples ou un modèle de chacune des classes est connu, la classification est dite supervisée, sinon la classification est dite non-supervisée. La classification supervisée nécessite de posséder un ensemble d'exemples d'éléments dans chacune des classes, qui est appelé ensemble d'apprentissage, alors que la classification non-supervisée ne nécessite aucun exemple.

Dans ce chapitre, nous présenterons rapidement les méthodes de classification non-supervisées (5.1), car elles ne répondent pas directement à notre choix. Puis, nous nous intéresserons plus en détail aux méthodes supervisées (5.2), en particulier au choix de l'ensemble d'apprentissage (5.2.1) et aux deux algorithmes les plus utilisés dans la littérature qui sont les Séparateurs à Vaste Marge (SVMs) et les Forêts Aléatoires (FA) (5.2.2). Nous détaillerons ensuite les ensembles de classifieurs, ainsi que les méthodes de fusion de classifications (5.3) qui ont inspirés notre méthode. Enfin, les critères d'évaluations de classification seront présentés dans la dernière partie de ce chapitre (5.4).

## 5.1 Classification non-supervisée

Les méthodes de classification non-supervisée, également appelées méthodes de *clustering*, permettent de regrouper un jeu de données (comme les pixels d'une image) en plusieurs sous-ensembles. Trois types de méthodes existent dans la littérature : les méthodes par agglomération, les méthodes par partitionnement et les méthodes probabilistes.

Parmi les méthodes par agglomération, on peut citer les méthodes de classification hiérarchique. Ces dernières sont soit ascendantes (agglomératives), si elles partent de chaque individu et cherchent à les regrouper, soit descendantes (par partition), si, au contraire, en partant de l'ensemble des individus, elles cherchent à les diviser en sous-groupes. Le regroupement ou la séparation des individus s'appuie sur une métrique de comparaison donnée. Ces méthodes fournissent une partition hiérarchique, qui peut être représentée sous la forme d'un arbre, appelé dendrogramme. Le choix d'une coupe optimale dans cet arbre permet de régler le nombre de classes, ainsi qu'un compromis entre la variance intra-groupe (homogénéité) et la variance inter-groupes (séparabilité).

Les k-moyennes (k-Means en anglais), introduites dans [MacQueen, 1967], sont une méthode de partitionnement, permettant de séparer un jeu de données en  $k$  classes, le paramètre  $k$  étant fixé en entrée du processus (*cf.* Figure 5.1). Bien que simple à mettre en œuvre et garantissant sa convergence, cette méthode nécessite de connaître préalablement le nombre de classes recherchées et ne converge que vers un minimum local. Plusieurs variantes existent dans la littérature, c’est le cas par exemple des k-médoïdes [Kaufman et Rousseeuw, 1987], où le remplacement du barycentre par le médoïde (le point central de la classe) permet de rendre la méthode plus robuste aux éléments aberrants et d’appliquer la méthode dans les cas où la somme entre éléments n’est pas définie. De même, les nuées dynamiques [Diday, 1971; Hartigan et Wong, 1979] sont une généralisation des k-moyennes qui remplacent le centre de classe par un noyau s’appuyant sur des éléments représentatifs de la classe. Cette variante permet également de réduire l’influence des valeurs aberrantes dans une classe. Enfin, la variante ISODATA introduite dans Ball et Hall [1965], permet de déterminer automatiquement le nombre de classes, grâce à deux seuils : l’inhomogénéité maximale d’un groupe et la séparabilité minimale entre deux groupes.




FIGURE 5.1 – Résultats de l’algorithme des k-moyennes appliqué sur l’extrait d’image Pléiades 3.2 avec, de gauche à droite,  $k = 3, 4$  et  $5$ .

Enfin, le troisième type de méthode cherche à modéliser la distribution de chacune des classes du jeu de données, c’est le cas en particulier des méthodes dites de modèles de mélanges. La distribution de chaque classe peut être modélisée par une fonction analytique (*e.g.*, gaussienne), dont les paramètres sont déterminés, la plupart du temps, par maximum de vraisemblance, par un algorithme EM (Espérance - Maximisation). La distribution de l’ensemble des données est ainsi modélisée par un mélange de gaussiennes.

Dans le domaine de la télédétection, les méthodes de classification non-supervisée sont utilisées pour la cartographie et la détection de changements. Par exemple, Wemmert et al. [2009] et Kurtz et al. [2010] proposent des méthodes de segmentation multi-résolution pour la cartographie de milieux urbains. Ces méthodes permettent de prendre en compte l’information complémentaire contenue dans deux images de résolutions différentes ( SPOT 4 à 20 m et Quickbird à 2,8 m). Par ailleurs, Ghosh et al. [2011] s’intéressent à la détection de chan-

gements dans une série temporelle d'images : un algorithme de classification non-supervisée floue est appliqué sur l'image de différence entre deux images de la série temporelle. D'autres méthodes de détection de changements fondées sur une classification non-supervisée sont décrites dans [Hussain et al. \[2013\]](#).

En conclusion, les méthodes de classification non-supervisée restent marginales dans le domaine de la cartographie de la couverture du sol car elles ne permettent pas de prendre en compte les spécificités thématiques attendues par l'utilisateur. Cependant, différentes méthodes permettent d'introduire des connaissances afin de contourner ce problème et sont présentées dans [\[Forestier, 2010\]](#), on parle alors de classification semi-supervisée [\[Bruzzone et al., 2006\]](#). Par ailleurs, ces méthodes peuvent servir de pré-traitement avant une classification supervisée, par exemple pour le calcul de sacs de mots visuels [\[Lienou, 2009\]](#), ou pour gérer les classes multi-aspects fréquentes dans les BDs OCS <sup>1</sup>.

## 5.2 Classification supervisée

Les méthodes de classification supervisées, contrairement aux méthodes non-supervisées vues dans le paragraphe précédent, cherchent à répartir un jeu de données en un ensemble de classes connues. Ainsi, ces méthodes permettent de « sémantiser » l'image. La connaissance de ces classes provient d'un jeu de données d'apprentissage : un ou plusieurs représentant(s) de chaque classe. L'ensemble d'apprentissage joue un rôle important dans les résultats de classifications, son choix est discuté dans la sous-section 5.2.1. Puis, un aperçu des différentes méthodes de classification supervisée est dressé dans la sous-section 5.2.2. En particulier, les deux algorithmes les plus utilisés dans la littérature (SVM et FA) sont détaillés dans cette sous-section.

### 5.2.1 Choix d'un ensemble d'apprentissage

La première étape consiste donc à choisir l'ensemble d'apprentissage et en particulier sa taille. Plusieurs études montrent que pour un grand nombre d'algorithmes de classification, la qualité des résultats augmente avec la taille de l'ensemble d'apprentissage [\[Zhuang et al., 1994; Foody et Arora, 1997; Foody et Mathur, 2004a\]](#). Par exemple, une partie de la littérature suggère d'utiliser  $30p$  points d'apprentissage par classe (où  $p$  est la dimension de l'espace des attributs) [\[Piper, 1992; Van Niel et al., 2005; Mather et Koch, 2010\]](#). Mais ce nombre peut être bien inférieur suivant le classifieur utilisé. Par exemple, dans le cas des SVMs, les données d'apprentissage ne sont pas utilisées pour décrire les classes avec précision, mais pour pouvoir les séparer. Ainsi, les SVMs ont besoin d'ensembles d'apprentissage plus petits mais bien construits [\[Foody et Mathur, 2006\]](#).

---

1. <http://www.cete-sud-ouest.developpement-durable.gouv.fr/1-apport-de-1-imagerie-a802.html>



En particulier, dans le cas d'une unique classe d'intérêt (*i.e.*, classification binaire), [Foody et al. \[2006\]](#) comparent quatre méthodes permettant de réduire la taille de l'ensemble d'apprentissage : la sélection des pixels les plus significatifs, la sélection par exclusion de classe, la description imprécise de classes spectralement très différentes et enfin la classification « une-classe ». Ces quatre méthodes donnent des résultats équivalents et permettent de réduire la taille de l'ensemble d'apprentissage de 90 % par rapport à une heuristique classique, tout en maintenant les taux de bonne classification (entre 95 et 97 % dans leur exemple).

Cependant, la taille de l'ensemble d'apprentissage n'est pas le seul paramètre à prendre en compte. En effet, suivant le classifieur utilisé, les meilleures distributions des échantillons seront très différentes. Par exemple, dans le cas des réseaux de neurones ou des SVMs, les points appartenant aux frontières entre les classes et les points entre les centres de gravité des classes seront les plus à même d'améliorer la qualité de la classification [[Foody, 1999](#); [Foody et Mathur, 2004a](#)]. Cependant, ces points ne décriront pas efficacement l'aspect général d'une classe, définie par son centre de gravité, et seront donc beaucoup moins utiles aux algorithmes modélisant les classes et non plus leurs frontières.

## 5.2.2 Algorithmes de classification supervisée

Un nombre très important d'algorithmes de classification supervisée existent et sont utilisés dans la littérature, en particulier dans le domaine de la télédétection [[Landgrebe, 2005](#); [Lu et Weng, 2007](#); [Tso et Mather, 2009](#)]. Ces algorithmes peuvent être regroupés en deux catégories : les méthodes paramétriques et les méthodes non-paramétriques.

Les méthodes paramétriques supposent que les pixels de chaque classe respectent une distribution (généralement gaussienne). Les paramètres de cette distribution (moyenne et écart-type pour une gaussienne) sont estimés à partir de l'ensemble d'apprentissage. C'est le cas, par exemple, des maximums de vraisemblance (Maximum Likelihood en anglais) ou de la méthode proposée dans [Trias-Sanz et Boldo \[2005\]](#). À l'inverse, les classifications non-paramétriques ne font aucune hypothèse sur la distribution des classes. On trouve dans cette catégorie les Séparateurs à Vaste Marge (SVMs) [[Boser et al., 1992](#); [Schölkopf et Smola, 2002](#)] et les Forêts Aléatoires (FA) [[Breiman, 2001](#)], mais également les méthodes par réseaux de neurones comme le perceptron multicouche [[Atkinson et al., 1997](#)], ou des méthodes plus simplistes comme les k-plus proches voisins [[Indyk et Motwani, 1998](#)], ou les arbres de décision [[Breiman et al., 1984](#)]. En pratique, les méthodes non-paramétriques sont plus efficaces sur des classes complexes, comme c'est le cas en télédétection, ou sur des données non spectrales (*e.g.*, texture) [[Paola et Schowengerdt, 1995](#); [Foody, 2002](#)]. De plus, les méthodes paramétriques sont considérées comme une base pour la classification de l'occupation du sol (avec les satellites actuels) [[Camps-Valls et Bruzzone, 2009](#)]. Notre choix s'est donc porté sur des méthodes non-paramétriques et en particulier sur

les SVMs et les FAs, qui outre leur utilisation très répandue, offrent la possibilité de calculer une probabilité d'appartenance d'un pixel à une classe (*cf.* ci-après). Cette mesure de probabilité d'appartenance permet de dériver une mesure d'incertitude dans la classification et ainsi de fournir un indicateur de fiabilité très utile pour garantir la robustesse de notre processus. Ainsi, nous décrirons ces deux méthodes dans les paragraphes suivants.

## SVM

Introduits par Cortes et Vapnik [1995] et Vapnik [1998], les Séparateurs à Vaste Marge (SVMs) sont une méthode de classification supervisée très répandue dans la littérature. En particulier, dans le domaine de la télédétection, Mountrakis et al. [2011] présentent l'avancée de leur utilisation dans des domaines variés comme l'estimation et le suivi de paramètres biophysiques [Kwiatkowska et Fargion, 2003; Knudby et al., 2010], ou l'étude de l'occupation du sol. Ainsi, des capteurs différents ont été évalués sur des surfaces variées, par exemple pour l'étude des espèces forestières avec la fusion de données Lidar et hyperspectrales [Dalponte, 2008], pour le suivi de la dégradation forestière à grande échelle avec des données MODIS [Cao et al., 2009], ou pour l'extraction de route à partir d'images Ikonos [Song et Civco, 2004; Huang et Zhang, 2009].

La force de la méthode des SVMs réside dans sa grande capacité de généralisation, sa capacité à produire de très bons résultats avec des ensembles d'apprentissage de tailles réduites, ainsi que dans sa faible sensibilité à la malédiction des grandes dimensions (phénomène de Hughes) [Belousov et al., 2002; Camps-Valls et al., 2004; Melgani et Bruzzone, 2004; Campedel et al., 2005; Mantero et al., 2005].

Les SVMs ont été définis initialement pour la classification de deux sous-ensembles linéairement séparables, dans un espace à  $q$  dimensions. Soit un ensemble d'apprentissage  $\{\mathbf{x}_i, y_i\}, i = 1, \dots, n; y_i \in \{-1, +1\}$ , où les  $\mathbf{x}_i$  sont les observations (attributs de classification) de dimension  $q$  et les  $y_i$  les étiquettes des classes associées. Le principe des SVMs est de trouver l'hyperplan séparant les deux sous-ensembles de points, en maximisant la généralisation de la classification, c'est-à-dire en séparant le mieux les points (vaste marge). Ainsi, on cherche un vecteur  $\mathbf{w}$  et un écart  $b$  vérifiant :

$$\min_{\mathbf{w}, b} \|\mathbf{w}\|^2 \quad \text{avec} \quad \forall i, y_i(\mathbf{w} \cdot \mathbf{x}_i + b) > 1. \quad (5.1)$$

La solution de ce problème  $\mathbf{w}^*$  peut être écrite sous la forme :

$$\mathbf{w}^* = \sum_{i=1}^n \alpha_i y_i \mathbf{x}_i. \quad (5.2)$$

où les coefficients  $\alpha_i$  sont positifs. Les  $\mathbf{x}_i$  pour lesquels  $\alpha_i > 0$  sont appelés *vecteurs de support*. La résolution du problème des SVMs est illustrée sur la Figure 5.2.




FIGURE 5.2 – Représentation mathématique de l'hyperplan issu des SVMs.

Cependant, lorsque les classes ne sont pas parfaitement linéairement séparables (*e.g.*, bruits dans les échantillons, ...), la contrainte introduite dans l'équation 5.1 ne peut pas être respectée. Dans ce cas, cette contrainte est relâchée en introduisant un terme de distance à l'hyperplan  $\{\xi_i\}_{i=1\dots n}$  et une contrainte pénalisant les  $\xi_i$  trop grands, correspondant aux valeurs aberrantes :

$$\min_{\mathbf{w}, b} \left\{ \|\mathbf{w}\|^2 + C \sum_{i=1}^n \xi_i \right\} \quad \text{avec} \quad \forall i, y_i(\mathbf{w} \cdot \mathbf{x}_i + b) > 1 - \xi_i. \quad (5.3)$$

Le paramètre  $C$  permet de régler la pénalisation liée aux valeurs aberrantes. Ainsi, une forte valeur de  $C$  pénalisera beaucoup les valeurs aberrantes, mais au risque d'un sur-ajustement (manque de généralisation). À l'inverse, avec une faible valeur, la généralisation est trop forte et beaucoup de valeurs sont alors considérées comme aberrantes. Cependant, [Belousov et al. \[2002\]](#) montrent qu'en pratique les SVMs sont peu sensibles à de grandes variations de  $C$ .

Dans le cas de données non-linéairement séparables, la méthode peut encore être adaptée en plongeant les données dans un espace de plus grande dimension, dans lequel le problème devient linéairement séparable, par une fonction non-linéaire  $\phi$  (*cf.* Figure 5.3). Cette projection ne se calcule pas de manière explicite, mais par l'utilisation d'une fonction noyau (défini positif)  $k$  :

$$(\phi(\mathbf{x}) \cdot \phi(\mathbf{x}_i)) = k(\mathbf{x}, \mathbf{x}_i). \quad (5.4)$$

Le noyau gaussien  $k(\mathbf{x}, \mathbf{x}_i) = \exp^{-\gamma \|\mathbf{x} - \mathbf{x}_i\|}$  est très utilisé dans la littérature. Le paramètre  $\gamma$  permet de contrôler la largeur de la gaussienne du noyau. La précision de la classification dépend de  $C$  et  $\gamma$ . En pratique, ces deux paramètres sont généralement fixés par validation croisée [[Hsu et al., 2003](#)], même si des méthodes d'optimisation différentes existent [[Fauvel, 2013](#)]. Par ailleurs, d'autres

noyaux, comme les noyaux polynomiaux, existent également [Zhu et Blumberg, 2002]. Mercier et Lennon [2003] évoquent différents noyaux, ainsi que l'utilisation de mélange de noyaux, permettant l'utilisation de données hétérogènes et/ou de différentes fonctions de distance.




FIGURE 5.3 – Illustration de l'utilisation d'un noyau  $\phi$  dans la méthode des SVMs (à gauche l'espace d'origine des attributs et à droite la projection grâce à une fonction noyau  $\phi$ .)

De plus, bien qu'ils aient été initialement conçus pour des classifications binaires, les SVMs ont été adaptés à la problématique de la classification multi-classes. Deux approches ont été proposées pour ramener les problèmes multi-classes à un ensemble de classifications binaires : le « un-contre-tous » et le « un-contre-un » [Huang et al., 2002; Melgani et Bruzzone, 2004]. Par ailleurs, Hsu et Lin [2002] proposent une méthode de SVMs multi-classes. Cette méthode, similaire à la méthode « un-contre-tous », mais effectuant une seule optimisation, permet d'obtenir les  $c$  hyperplans en un seul calcul ( $c$  étant le nombre de classes). De plus, cette méthode permet de réduire la taille de l'ensemble d'apprentissage et de ne fixer qu'une seule fois les paramètres  $C$  et  $\gamma$ .

Les SVMs ne fournissent qu'une classification (une étiquette) sans calculer de probabilité d'appartenance d'un point à une classe. Cependant, la calibration de Platt permet d'estimer des probabilités d'appartenance à chacune des classes dans le cas d'une classification binaire [Platt, 1999; Lin et al., 2007]. Dans cette méthode, la probabilité est estimée en ajustant un modèle de régression logistique aux résultats de la classification. Dans le cas multi-classes, Wu et al. [2004] utilisent les probabilités des différentes classifications de type « un-contre-un » pour calculer une probabilité d'appartenance à chacune des classes.

Enfin on peut citer l'une des nombreuses variantes des SVM, appelée *one-class SVM* [Braun, 2010; Muñoz Marí, 2010; Gómez-Chova et al., 2011] et qui permet, comme son nom l'indique, de classifier une seule classe, sans connaître les autres classes. La méthode consiste à trouver la plus petite sphère englo-

bant l'ensemble d'apprentissage dans l'espace des attributs. Ainsi, la limite de la sphère permet de classer les données en deux : celles appartenant à la classe et les autres. Cette méthode permet de diminuer le nombre de pixels d'apprentissage nécessaires.

## Forêts aléatoires

Les Forêts Aléatoires (FA) ont été introduites par Breiman [2001] et sont définies comme l'agrégation d'une collection de prédicteurs, un arbre de décision. Genuer [2010] souligne que, dans la littérature, les FAs sont généralement confondues avec un cas particulier des FAs, appelées *Random Forests-RI* (forêts aléatoires à variables d'entrée aléatoire, en anglais *Random Forests with Random Inputs*), introduites dans le même article. Nous parlerons dans ce manuscrit de FAs pour désigner les *Random Forest-RI* de Breiman.

Le principe des FAs est le suivant. Un ensemble d'échantillons  $(\mathcal{L}_n^{\Theta_1}, \dots, \mathcal{L}_n^{\Theta_K})$  est généré. Puis un arbre de décision CART (*Classification and Regression Tree*) [Breiman et al., 1984] est construit sur chaque échantillon  $\mathcal{L}_n^{\Theta_k}$  (cf. Figure 5.4). Chaque nœud de l'arbre est découpé à partir d'un tirage aléatoire de  $m$  variables (attributs) ; on cherche la meilleure coupure uniquement suivant ces  $m$  attributs. Enfin, le résultat de la classification est obtenu par la méthode du vote majoritaire : chaque arbre vote pour une classe, la classe ayant le plus de votes l'emporte. Ainsi, deux paramètres entrent en jeu : le nombre d'arbres utilisés  $K$  et le nombre de variables  $m$  tirées à chaque construction d'un nœud. Le premier paramètre est arbitrairement fixé à une valeur importante (e.g., 500). Le second paramètre  $m$  n'a pas une grande influence et est généralement fixé à la valeur de la racine carré du nombre de variables [Gislason et al., 2006]. Par ailleurs, il existe de nombreuses variantes des FAs décrites dans [Criminisi et Shotton, 2013], comme les *random ferns*, qui sont plus rapides que les FAs et donnent des résultats similaires [Bosch et al., 2007].

Les FAs ont montré de meilleures performances de classification que les méthodes classiques de Boosting [Breiman, 2001] ou de SVMs [Pal, 2005]. Les FAs sont également capables de traiter d'importants jeux de données, avec un grand nombre de dimensions. Pour ces différentes raisons, les FAs ont été largement utilisées dans le domaine de la télédétection [Pal, 2005; Dalla Mura et al., 2010; Escalante-Ramirez, 2012; Longbotham et al., 2014].

Par ailleurs, Breiman [2001] a également introduit deux mesures intéressantes obtenues grâce aux FAs : l'importance des variables et la marge. La première permet de qualifier l'utilité de chacune des variables dans la classification [Strobl et al., 2007]. Ainsi, l'importance des variables permet de faire de la sélection d'attributs [Chehata et al., 2009; Genuer et al., 2010; Löw et al., 2013]. La seconde mesure obtenue, la marge, permet de mesurer la confiance de la classification d'un élément (pixel).

L'importance de la variable  $X^j$ ,  $j \in \{1, \dots, q\}$  ( $q$  étant le nombre de variables), est définie comme suit. Soit  $\mathcal{L}_n^{\Theta_k}$  un échantillon et  $OOB_k$  l'ensemble des

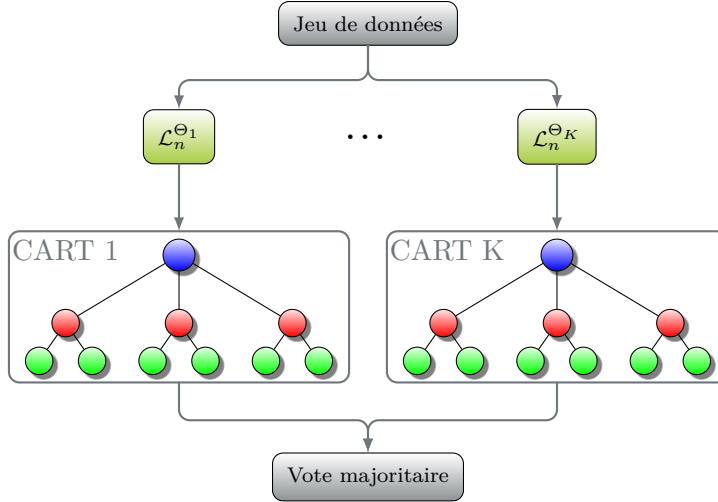


FIGURE 5.4 – Schéma des Forêts Aléatoires : une arbre de décision CART est créé pour sur chaque sous-ensemble de données  $\mathcal{L}_n^{\Theta_i}$ , puis la classification est obtenue par vote majoritaire.

observations qui n'apparaissent pas dans  $\mathcal{L}_n^{\Theta_k}$  (*out-of-bag*). On calcule alors l'erreur commise sur  $OOB_k$  par  $\mathcal{L}_n^{\Theta_k}$  (la proportion de mal classés), notée  $errOOB_k$ . Puis on permute aléatoirement les valeurs de la  $j^e$  variable dans l'échantillon  $OOB_k$ , pour obtenir  $\widetilde{OOB}_k^j$ . Enfin, on calcule  $err\widetilde{OOB}_k^j$ , l'erreur sur l'échantillon  $\widetilde{OOB}_k^j$ . L'importance de la variable  $j$ , notée  $VI(X^j)$  est alors définie comme la moyenne des différences de ces erreurs (Équation 5.5).

$$VI(X^j) = \frac{1}{K} \sum_{k=1}^K (err\widetilde{OOB}_k^j - errOOB_k), \quad (5.5)$$

où  $K$  est le nombre d'arbres.

La **marge** (*margin* en anglais) d'un élément  $X$  pour la classe  $Y$ , est définie comme la différence entre le nombre moyen d'arbres votant pour la classe  $Y$  et le plus grand nombre moyen d'arbres votant pour une autre classe que  $Y$  :

$$M(X, Y) = \frac{1}{K} \sum_{k=1}^K I(h_k(X) = Y) - \max_{j \neq Y} \left[ \frac{1}{K} \sum_{k=1}^K I(h_k(X) = j) \right], \quad (5.6)$$

où  $h_k$  est la fonction renvoyant la décision de l'arbre  $k$  et  $I$  la fonction indicatrice ( $I(x)$  renvoie 1 si  $x$  est vrai et 0 sinon). La marge est positive si l'échantillon  $X$  est classé dans la classe  $Y$  et elle est négative sinon. Ainsi, plus la marge est importante, plus la confiance dans la classification est forte.

## 5.3 Ensemble et fusion de classifieurs

Les méthodes par ensemble de classifieurs cherchent à améliorer la précision des classifications [Roli et al., 2001; Banfield et Hall, 2007; Benediktsson et al., 2007; Lu et Weng, 2007]. En effet, beaucoup de travaux montrent que l'utilisation de plusieurs classifieurs permet d'améliorer la précision, par rapport à l'utilisation d'un unique classifieur [Warrender et Augusteijn, 1999; Steele, 2000; Huang et Lees, 2004; Zhang, 2010]. La littérature abondante sur ce sujet peut être séparée entre, d'une part, la description du choix du meilleur ensemble de classifieurs [Kim et al., 2003; Malisiewicz et al., 2011] et d'autre part les méthodes de fusion des classifications ainsi obtenues [Liu et al., 2004; Ceamanos et al., 2010; Tupin et al., 2014a]. Dans cette partie, nous évoquerons dans un premier temps l'utilisation d'ensembles de classifieurs, en particulier dans le domaine de la télédétection (5.3.1), puis nous proposerons un aperçu des méthodes de fusion de classifications existant dans la littérature (5.3.2).

### 5.3.1 Ensemble de classifieurs

Un grand nombre d'approches de construction d'ensembles de classifieurs existent dans la littérature [Krogh et Vedelsby, 1995; Kim et al., 2003; Benediktsson et al., 2007]. De manière générale, les recherches théoriques et empiriques s'accordent à dire que pour être performants, les classifieurs doivent être indépendants entre eux, *i.e.*, chaque classifieur se trompe sur une partie différente de l'ensemble d'entrée [Krogh et Vedelsby, 1995; Kittler, 1998]. Cependant, Kuncheva et Whitaker [2000] tempèrent cette remarque en montrant que des classifieurs dépendants peuvent également améliorer la précision de la classification.

Par ailleurs, deux stratégies distinctes de construction d'ensemble de classifieurs existent dans la littérature : soit en manipulant l'ensemble d'apprentissage, soit en combinant différents algorithmes de classification.

Il peut s'agir dans un premier temps de générer différents classifieurs en manipulant l'ensemble d'apprentissage, c'est le cas par exemple des deux méthodes les plus connues le *bagging* et le *boosting*. Le *bagging*, introduit par Breiman [1996a], consiste à entraîner un même classifieur (initialement un arbre de décision) sur différents ensembles d'apprentissage afin d'obtenir des prédicteurs différents. Contrairement au *bagging*, où les tirages d'ensembles d'apprentissages sont indépendants, le *boosting* [Freund et Schapire, 1996] tire en priorité des observations mal prédites par les prédicteurs précédents. Une troisième méthode, appelée *random subspace* et introduite par Ho [1998], consiste à tirer aléatoirement un sous-ensemble de variables pour construire chaque prédicteur. L'utilisation conjointe du *bagging* et du *random subspace* a donné naissance aux FAs présentées dans la section 5.2.2. Mais ces méthodes peuvent également être utilisées avec d'autres classifieurs comme les SVMs [Kim et al., 2003].

D'autre part, l'ensemble de classifieurs peut être construit par combinai-



son de différents algorithmes de classification [Smits, 2002]. Cette méthode est très adaptée pour l'utilisation de données de télédétection multi-capteurs ou multi-dates [Briem, 2002]. Par exemple, Benediktsson et Kanellopoulos [1999] combinent un algorithme de type réseau de neurones avec des méthodes statistiques afin de classer respectivement des données multi-capteurs et de données hyperspectrales. Bruzzone et al. [2002] appliquent une telle méthode sur une série temporelle d'images Landsat 5.

Par ailleurs, Malisiewicz et al. [2011] proposent de construire un ensemble de classifieurs en entraînant un SVM sur chaque objet (exemple) de la BD. La méthode, nommée Exemplar-SVMs est appliquée à la détection d'objets (de type voitures, vélos, ...) sur un ensemble de photographies.

### 5.3.2 Fusion de classifieurs

La méthode de fusion de classifieurs est un élément important dans les méthodes d'ensemble de classifieurs, car c'est à cette étape que la décision finale de classification est prise. Un grand nombre de travaux abordant différents types de méthodes s'intéresse donc à ce point [Leblanc et Tibshirani, 1996; Merz, 1999; Merz et Pazzani, 1999; Mojirsheibani, 1999; Tupin et al., 2014a].

Par exemple, les décisions peuvent être fusionnées par des méthodes simples, comme un vote majoritaire, comme dans les FAs, par somme ou produit des décisions, par seuillage [Steele, 2000; Liu et al., 2004], par régression linéaire [Wolpert, 1992; Breiman, 1996b], ou encore par Aggregation Weight-Functional Operators (AWFO) [Arif et al., 2006]. Cette dernière méthode prend en compte la distribution générale des données afin de pondérer de manière efficace les différentes classifications.

D'autre part, un grand nombre de méthodes s'appuie sur la théorie des ensembles flous. Par exemple, la théorie de l'évidence (Dempster-Shafer, DST) [Dempster, 1960; Shafer, 1976] a été utilisée sur des applications variées comme la classification de milieux urbains par imagerie satellitaire THR (IKONOS) [Fauvel et al., 2006] ou sur des données SAR [Tupin et al., 1999; Chanussot et al., 1999]. Par suite, la théorie de Dezert-Smarandache (DSmT) est une extension de la DST [Smarandache, 1991; Smarandache et Dezert, 2006] qui en améliore les performances. Elle est utilisée par exemple dans [Corgne et al., 2004] pour la détection de changements d'occupation du sol.

Par ailleurs, plusieurs articles proposent de fusionner les classifieurs en introduisant les sorties de chaque classification en entrée d'un nouveau processus de classification (ici un SVM), Waske et Benediktsson [2007] appliquent cette méthode pour la fusion de données issues de différents capteurs, alors que Ceamanos et al. [2010] l'appliquent sur des données hyperspectrales. Dans ce papier, les bandes spectrales sont regroupées par sous-ensembles ayant une forte corrélation, puis une classification est réalisée sur chaque sous-ensemble. Finalement, les classifications sont fusionnées grâce à un nouveau SVM.

## 5.4 Évaluation d'une classification

Afin de qualifier la qualité d'un résultat de classification, différents critères ont été proposés dans la littérature [Metz, 1978; Davis et Goadrich, 2006; Fawcett, 2006] et seront détaillés ici. Tous ces critères nécessitent d'avoir une vérité terrain : un ensemble de pixels dont on connaît *a priori* la classe d'appartenance, mais qui ne rentre pas dans le processus d'apprentissage (c'est un ensemble distinct de l'ensemble d'apprentissage). Ainsi, dans le cas d'une classification binaire, on suppose que l'on dispose d'un ensemble d'éléments étiquetés respectivement par **p** (+1) ou **n** (-1) :  $\{\mathbf{x}_i, y_i\}, i = 1, \dots, n; y_i \in \{-1, +1\}$ , cette ensemble est appelé vérité terrain. Par ailleurs, l'algorithme de classification, que l'on souhaite évalué, donne pour chaque élément, une étiquette  $p'$  (+1) ou  $n'$  (-1) :  $\{\mathbf{x}_i, y'_i\}, i = 1, \dots, n; y'_i \in \{-1, +1\}$ . On peut alors construire la matrice de confusion  $MC = (m_{c_i, c_j})_{(c_i, c_j) \in \{-1, +1\}^2}$ , où chaque élément  $m_{i,j}$  correspond au nombre d'éléments classés en  $c_i$  et dont son étiquette selon la vérité terrain est  $c_j$  (cf. Figure 5.5). La matrice permet ainsi de définir 4 types de mesures :

- les vrais positifs (VP) :  
les éléments correctement classés positifs ( $y' = p'$  et  $y = p$ );
- les faux positifs (FP) :  
les éléments classés positifs à tort ( $y' = p'$  et  $y = n$ );
- les faux négatifs (FN) :  
les éléments classés négatifs à tort ( $y' = n'$  et  $y = p$ );
- les vrais négatifs (VN) :  
les éléments correctement classés négatifs ( $y' = n'$  et  $y = n$ ).

Par ailleurs, on notera  $P$  (respectivement  $P'$ ) le nombre d'éléments positifs de la vérité terrain (respectivement de la classification) et de manière analogue  $N$  et  $N'$  le nombre d'éléments négatifs de la vérité terrain et de la classification. Ces 4 nombres correspondent à la somme des éléments de la matrice de confusion par ligne (pour  $P'$  et  $N'$ ) et par colonne (pour  $P$  et  $N$ ).

Cette matrice de confusion permet de dériver plusieurs mesures pour juger de la qualité d'une classification comme le rappel, la précision, la F-mesure, le taux de bonne classification et l'indice  $\kappa$ . Le rappel est défini comme le nombre de pixels correctement classés positifs sur le nombre de pixels positifs de la vérité terrain (Équation 5.7). Il permet de juger de la capacité de la classification à bien faire ressortir les éléments de la classe **p**, *i.e.*, ne pas oublier d'éléments dans **p**. La précision est définie comme le nombre de pixels correctement classés positifs sur le nombre de pixels classés positifs (Équation 5.8). Il permet de juger de la capacité de la classification à ne pas tout classer positifs, *i.e.*, ne pas prendre trop d'éléments dans **p**. La F-mesure est la moyenne harmonique entre le rappel et la précision (Équation 5.9), elle permet de prendre en compte conjointement le rappel et la précision de la classification. Le taux de bonne classification (*accuracy* en anglais) est le rapport entre le nombre de pixels correctement classés sur le nombre total de pixels (Équation 5.10). Il permet de juger de manière plus globale la qualité de la classification. L'indice  $\kappa$ , ou  $\kappa$  de Cohen [Pontius

		<b>Vérité terrain</b>		
		<b>p</b>	<b>n</b>	<b>total</b>
<b>Classification</b>	<b>p'</b>	Vrai Positif	Faux Positif	<b>P'</b>
	<b>n'</b>	Faux Négatif	Vrai Négatif	<b>N'</b>
<b>total</b>		<b>P</b>	<b>N</b>	

FIGURE 5.5 – Matrice de confusion pour l'évaluation d'une classification binaire.

et Millones, 2011], permet de prendre en compte l'effet d'un accord aléatoire, et prend en compte  $P_o$  (la proportion d'accord observée, qui est le taux de bonne classification) et  $P_e$  (la proportion d'accord aléatoire), cf. Équations 5.12 et 5.13. Cet indice varie entre 0 (dans le cas très mauvais accord) et 1 (dans le cas d'un très bon accord). Un indice supérieur à 0,6 est considéré comme bon, et très bon s'il est supérieur à 0,8. Enfin, ces notions sont généralisables dans le cas d'une classification multi-classes. On parle alors de précision utilisateur, pour évaluer la précision d'une classe par rapport aux autres classes et de précision producteur pour évaluer son rappel. Le taux de bonne classifications garde également la même définition.

$$\text{Rappel} = \frac{VP}{P} \quad (5.7)$$

$$\text{Précision} = \frac{VP}{P'} \quad (5.8)$$

$$\text{F-mesure} = \frac{2}{1/\text{Précision} + 1/\text{Rappel}} \quad (5.9)$$

$$\text{ACC} = \frac{VP + VN}{P + N} \quad (5.10)$$

$$\kappa = \frac{P_o - P_e}{1 - P_e} \quad (5.11)$$

$$P_o = \text{ACC} \quad (5.12)$$

$$P_e = \frac{P * P' + N * N'}{(P + N)^2} \quad (5.13)$$

Enfin, dans le cas où la classification dépend d'un seuil, une étude plus précise de la qualité de la classification permettant de rester indépendante de ce seuil est permise par l'analyse de la courbe sensibilité / spécificité, ou courbe ROC

(Receiver Operating Characteristic) [Metz, 1978; Fawcett, 2006]. La sensibilité, ou taux de faux positifs (TFP) est le rapport entre le nombre de faux positifs et le nombre d'éléments positifs dans la vérité terrain (Équation 5.14), alors que la spécificité (ou taux de vrais négatifs TVN) est le rapport entre le nombre de vrais négatifs sur le nombre d'éléments négatifs de la vérité terrain (Équation 5.15). De manière générale, plus la courbe est en haut à gauche (forte sensibilité et forte spécificité) plus la qualité de la classification est importante.

$$\text{TFP} = \frac{\text{FP}}{\text{P}} \quad (5.14)$$

$$\text{TVN} = \frac{\text{VN}}{\text{N}} \quad (5.15)$$




FIGURE 5.6 – Courbe ROC : variation de l'opposé de la spécificité en fonction de la sensibilité. Cette courbe permet de juger de la qualité d'une classification dépendant d'un seuil, plus la courbe est au dessus de la droite ( $y = x$ ), plus la qualité est importante.

## 5.5 Conclusion

Dans un premier temps, nous avons pu voir dans ce chapitre que deux types de classifieurs semblent se démarquer, il s'agit d'une part des classifieurs par SVM et d'autre part des FA. Par ailleurs, ces deux classifieurs sont disponibles dans des bibliothèques open-source : la LibSVM [Chang et Lin, 2011] et OpenCV [Bradski, 2000], qui sont toutes disponibles dans la bibliothèque OTB [Inglada et Christophe, 2009].

D'autre part, nous avons également vu que la multiplication de classifieurs et leur fusion est une stratégie de plus en plus courante dans la littérature et qui permet d'améliorer grandement la qualité des classifications obtenues.

Ainsi, nous proposons dans notre méthode d'utiliser un ensemble de classifieurs qui, à la manière des Exemplar-SVMs, va permettre d'apprendre l'apparence de tous les objets de la BD à mettre à jour. Chaque classification sera de type « un-contre-tous » afin de pouvoir discriminer au mieux l'apparence du thème de l'objet des autres thèmes de la BD. Enfin, les différentes méthodes de fusion existantes devront être comparées afin de juger de leur pertinence sur notre jeu de données.

## Troisième partie

# LUPN : Méthode générique de mise à jour de bases de données géographiques et son adaptation à la problématique des données d'Occupation du Sol





# Méthodologie générique de mise à jour de bases de données géographiques (MLMOL)

---

## Sommaire

---

<b>7.1</b>	<b>Intégration de MLMOL dans la chaîne EPN</b>	<b>98</b>
7.1.1	Extraction d'attributs	98
7.1.2	Sélection d'attributs	100
7.1.3	Choix du classifieur	103
7.1.4	Choix de la méthode de fusion	104
7.1.5	Premiers pas vers un passage à l'échelle	106
<b>7.2</b>	<b>Expériences sur un jeu de données généré</b>	<b>108</b>
7.2.1	Description du jeu de données	108
7.2.2	Attributs et classification	108
7.2.3	Complétion	109
7.2.4	Mise à jour	109
7.2.5	Complétion et mise à jour conjointes	110
<b>7.3</b>	<b>Conclusion</b>	<b>110</b>

---

La chaîne de traitements  $\mathbb{L}\mathbb{P}\mathbb{N}$ , permettant la mise à jour de BDs d'OCS, est fondée sur une méthode d'apprentissage et de classification multi-niveau MLMOL, décrite dans ce chapitre. Son adaptation aux BDs d'OCS est traitée dans le chapitre suivant.

La méthode MLMOL a été conçue afin de répondre au mieux aux problèmes soulevés dans la section 1.3 en prenant en compte les éléments issus de l'état-de-l'art décrits dans la Partie II, en particulier sur les méthodes de détection de changements (*cf.* chapitre 2) et les algorithmes de classifications (*cf.* chapitre 5).

- L'apprentissage sur des données imparfaites est rendu possible grâce à la sélection des points d'apprentissage (6.2.1) et la fusion des classifications (6.2.2).
- L'utilisation de classifications de type « un-contre-tous » (6.2.1) permet la méthode MLMOL de s'adapter au mieux aux différentes classes existantes.
- La multiplication des classifications par classes et leur fusion (6.2) permet d'améliorer la robustesses des classifications (5.3), en particulier dans le cas de classes pouvant contenir des objets de différentes apparences.

Ce chapitre est divisé en deux parties. Dans un premier temps, les notations utilisées et la structure hiérarchique des bases de données sont détaillées (section 6.1), puis la méthode d'inspection s'inspirant de cette structure est présentée dans la section 6.2. Dans un second temps, un jeu de données simulées est utilisé afin de valider la méthode sans prendre en compte les problèmes liés aux attributs de classifications. Les données conçues à cette fin et les expérimentations sont détaillées dans la section 6.3. Ces premières expérimentations ont permis de valider la robustesse de la méthode face à des classes différentes ayant des apparences semblables et face à des classes non-homogènes.

## 6.1 Notations

### 6.1.1 Structure des bases de données géographiques

Les bases de données (BDs) géographiques ont une structure hiérarchique : une BD est composée d'un ensemble de classes  $\{C_j\}_{j \in [1, N_C]}$ ,  $N_C$  étant le nombre de classes considérées dans la BD (ex : routes, forêts, champs, *etc.*). L'ensemble des classes de la BD est connu à l'avance (nomenclature). De plus, les classes peuvent être imbriquées (nomenclature hiérarchique). Chaque classe  $C_j$  (uniquement celles de plus bas niveaux dans le cas d'une nomenclature hiérarchique) est elle-même associée à un ensemble d'objets disjoints spatialement  $\{O_i^j\}_{i \in [1, N_{C_j}]}$ ,  $N_{C_j}$  étant le nombre d'objets associés à la classe  $C_j$ , (*cf.* Figure 6.2). En pratique, ces objets sont des polygones 2D géoréférencés. Par ailleurs, ces polygones sont issus de travaux de photo-interprétation sur des images aériennes ou satellite (antérieures à celles utilisées pour la mise à jour) ou de relevés terrain. Ils subissent dans un grand nombre de cas des transformations géométriques (*e.g.*, généralisation, *etc.*) pour être mis en conformité avec les spécifications de la BD. Ces modifications sont supposées inconnues ici.

# LUPIN

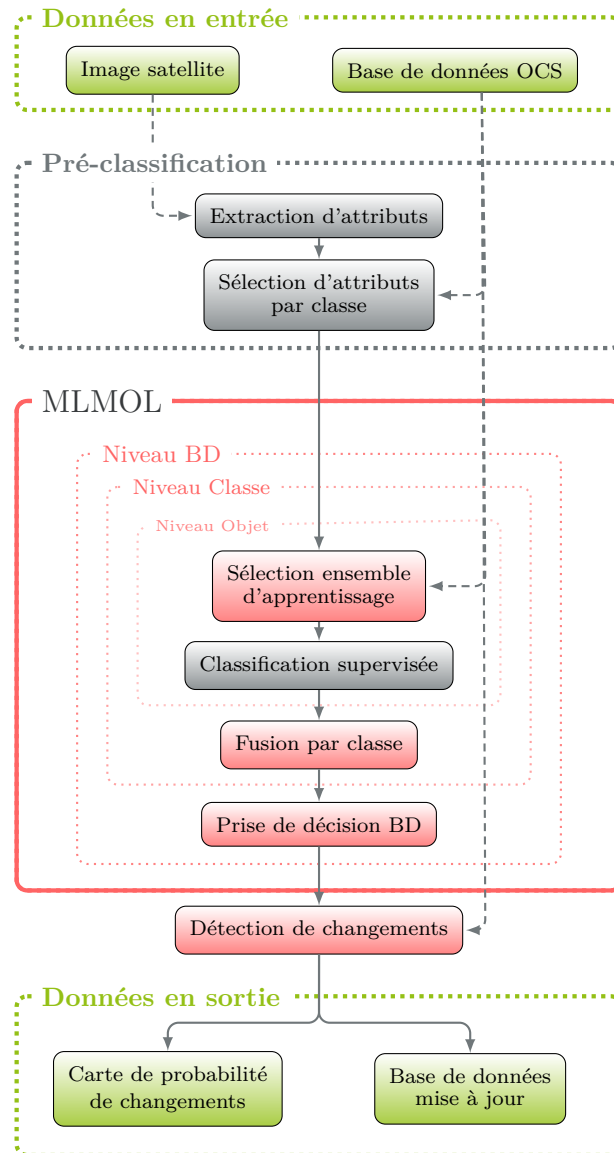


FIGURE 6.1 – Schéma général du processus de mise à jour et de détection de changements dans une BD géographique. La méthode d'apprentissage multi-niveaux MLMOL est détaillée dans ce chapitre.

Cette structure hiérarchique de la BD révèle trois niveaux d'analyse possibles : aux niveaux des objets, des classes et de la BD elle-même.




FIGURE 6.2 – Représentation d'une base de données géographiques : une BD est composée de différentes classes  $C_j$ , elles-mêmes sont composées de différents objets ( $O_i^j$ ).

### 6.1.2 Lien entre base de données et image

Afin de pouvoir utiliser une image satellite (ou aérienne) pour la mise à jour d'une BD géographique, l'image doit être corrigée des déformations géométriques dues au capteur et à la topologie du terrain. Ce traitement est appelé ortho-rectification et permet d'obtenir une image géoréférencée, mise en correspondance avec la BD géographique. Ainsi, chaque objet  $O_i^j$  de la classe  $C_j$  de la BD est associé à une région  $R_i^j$  de l'image, par une fonction de projection  $\mathcal{I}$  dépendant de cette image, Équation 6.1. Chaque région  $R_i^j$  est un ensemble de pixels de l'image. Par la suite, l'objet  $O_i^j$  et sa projection sur l'image  $R_i^j$  seront confondus, et seule la notation  $O_i^j$  sera utilisée. Une erreur de géoréférencement de l'image ou de la BD entraînera un décalage lors de leur superposition. Ce décalage peut être interprété comme un changement et pourra donc être pris en compte par notre méthode, dans la mesure où ce décalage est petit comparé à la taille des objets de la BD (en particulier les objets allongés comme les routes).

$$\forall j \in [1, N_C], \quad \forall i \in [1, N_{C_j}], \quad R_i^j = \mathcal{I}(O_i^j). \quad (6.1)$$

De plus, lorsqu'il n'y aura pas d'ambiguïté possible, un objet  $O_i^j$  et sa classe associée  $C_j$ , seront simplement notés  $O$  et  $C$ .

En pratique, la BD et l'image n'ont pas forcément la même emprise et la BD peut contenir des zones non étiquetées. Ainsi, la projection de l'ensemble des

objets de toutes les classes d'une même BD ne couvre pas forcément l'ensemble de la zone concernée  $\Omega$  : le reste de la zone est appelé dans ce document *extérieur*.

$$\Omega = \mathcal{I}(\text{BD}) \cup \text{extérieur}.$$

Ainsi, chaque pixel de l'image est initialement étiqueté soit par une classe de la BD, soit comme étant *extérieur* à la BD, par l'étiquette  $Ex$ . L'étiquette d'un pixel  $p$  de l'image  $I$ , est donnée par la fonction  $L_{\text{BD}}$  :

$$\begin{aligned} L_{\text{BD}} : I &\longrightarrow \{C_j\}_{j \in [1..N_C]} \cup \{Ex\} \\ p &\longmapsto L_{\text{BD}}(p) \end{aligned}$$

### 6.1.3 Classification supervisée binaire

Une classification supervisée consiste en une étape d'apprentissage utilisant un ensemble d'apprentissage, puis en une étape de classification. Les notations utiles à ces deux étapes sont détaillées ci-après.

L'apprentissage est réalisé à partir d'un sous-ensemble de pixels  $E$  de l'image  $I$ , étiqueté en deux classes :  $\{C_1, C_2\}$ , par la fonction  $l$ , cf. Équation 6.2. Ce dernier sera noté  $\{E, l\}$ , ou comme la réunion de deux sous-ensembles de  $E$ ,  $(E_1, E_2)$ , tel que  $E_1 = \{p \in E, l(p) = C_1\}$  et  $E_2 = \{p \in E, l(p) = C_2\}$ .

$$\begin{aligned} l : E &\longrightarrow \{C_1, C_2\} \\ p &\longmapsto l(p) \end{aligned} \tag{6.2}$$

La méthode de classification permet de définir, à partir d'un ensemble d'apprentissage  $\{E, l\}$ , une fonction de classification  $l_c$  étendue à toute l'image :

$$\begin{aligned} l_c : I &\longrightarrow \{C_1, C_2\} \\ p &\longmapsto l_c(p) \end{aligned}$$

Suivant la méthode choisie, elle permet également de définir une mesure de confiance, pouvant être interprétée comme la probabilité qu'un pixel de l'image  $p$  appartienne à la classe  $C_1$ ,  $P(l_c(p) = C_1)$ , sa probabilité d'appartenance à la classe  $C_2$ ,  $P(l_c(p) = C_2)$ , étant égale à  $1 - P(l_c(p) = C_1)$ . La carte de confiance, interprétée comme une carte de probabilité d'appartenance à une classe,  $\mathcal{P}(E, l)$ , ou de manière équivalente  $\mathcal{P}(E_1, E_2)$ , est définie de la manière suivante :

$$\begin{aligned} \mathcal{P}(E, l) = \mathcal{P}(E_1, E_2) : I &\longrightarrow [0, 1] \\ p &\longmapsto P(l_c(p) = C_1) \end{aligned}$$

Le rappel et la précision d'une classification ont été définis dans la section 5.4. Nous rappelons ici leur formulation avec les notations introduites dans ce chapitre. Le rappel de la classe  $C_i$  par une classification  $l_c$ , étant donné une vérité terrain (un ensemble de pixels dont on connaît *a priori* l'étiquette)  $VT = \{E_{VT}, l_{VT}\}$ , est défini comme le rapport entre le nombre de pixels de  $E_{VT}$  bien étiquetés par  $l_c$  dans la classe  $C_i$  et le nombre de pixels de  $E_{VT}$  ayant l'étiquette  $C_i$  :

$$Rappel(l_c, VT, C_i) = \frac{\#\{p \in E_{VT}, l_{VT}(p) = C_i \text{ et } l_c(p) = l_{VT}(p)\}}{\#\{p \in E_{VT}, l_{VT}(p) = C_i\}}.$$

Et, la précision de  $C_i$  est définie comme le rapport entre le nombre de pixels de  $E_{VT}$  bien étiquetés par  $l_c$  dans la classe  $C_i$  et le nombre de pixels de  $E_{VT}$  étiquetés  $C_i$  par  $l_c$  :

$$Précision(l_c, VT, C_i) = \frac{\#\{p \in E_{VT}, l_{VT}(p) = C_i \text{ et } l_c(p) = l_{VT}(p)\}}{\#\{p \in E_{VT}, l_c(p) = C_i\}}.$$

## 6.2 Inspection hiérarchique de la base de données géographique

Ainsi, la méthode Multi Level, Multi Object Learning (MLMOL), illustrée sur la Figure 6.3, repose sur une inspection entière de la BD, en respectant la structure hiérarchique, décrite dans la section 6.1, selon un processus ascendant (bottom-up). L'introduction d'une approche de type « Exemplar-SVM » [Malisiewicz et al., 2011], *i.e.*, une classification pour chaque objet de la BD (inspection au niveau objet) et la fusion au niveau de la classe permettent d'apprendre les différentes apparences d'une classe, et ainsi de consolider la prise de décision au niveau de la BD. Trois éléments distincts sont ainsi obtenus :

- 1) une carte de probabilité de changements entre la BD et la nouvelle image ;
- 2) une BD mise à jour ;
- 3) une complétion des zones non étiquetées par la BD initiale.

Un raisonnement « top-down » peut être envisagé en perspective afin de régulariser la classification obtenue et pour introduire de l'information contextuelle.

### 6.2.1 Niveau objet

L'examen au niveau de l'objet est fondé sur une classification binaire supervisée utilisant des caractéristiques calculées sur l'image (décrites dans la sous-section 6.1.3). Comme on a pu le voir dans la sous-section 5.2.1, l'ensemble d'apprentissage joue un rôle important dans le résultat de la classification. Ainsi, pour chaque objet, le classifieur est entraîné sur un sous-ensemble de pixels capables de discriminer au mieux l'objet du reste des pixels de l'image hors de

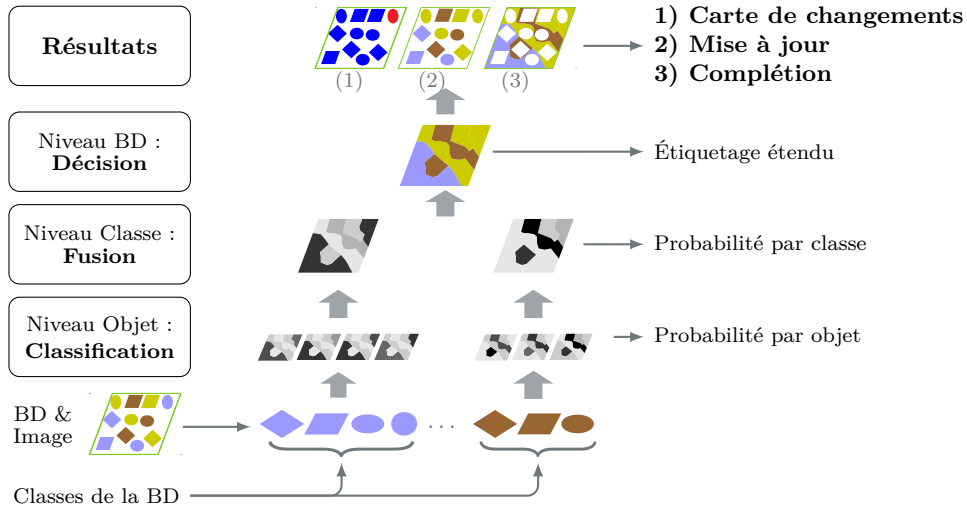


FIGURE 6.3 – Schéma détaillé de la méthode d’apprentissage et de classification MLMOL pour la mise à jour et la complétion de BDs géographiques.

la classe courante. Ce choix est fondé sur l’adaptation de deux méthodes d’ensemble de classifieurs vues dans la sous-section 5.3.1 : le *bagging* et le *boosting*. Les ensembles d’apprentissage sont tirés aléatoirement de manière indépendantes comme dans le *bagging*, mais une mesure de la pertinence de l’ensemble choisi est ajouté, permettant d’améliorer le classifieur en augmentant le nombre de tirages (comme dans le *boosting*). Ainsi, cette méthode peut être appliquée à n’importe quel classifieur. Cependant, dans le cas où un SVM est utilisé, la sélection de l’ensemble d’apprentissage peut être remplacée par la sélection spécifique, comme une sélection des points en bord de classe dans l’espace des attributs proposée par Foody et Mathur [2004b].

La pertinence de l’ensemble choisi est mesurée par le calcul du rappel de la classification sur l’objet en cours. Cette mesure permet de garantir que le classifieur, entraîné à partir de l’ensemble d’apprentissage sélectionné, décrit au mieux l’apparence de la plus grande partie de l’objet. Elle permet de prendre en compte d’éventuels changements dans la BD, mais également d’éventuels problèmes de recalages entre la BD et l’image.

### Choix de l’ensemble d’apprentissage

Deux ensembles de pixels sont choisis, un parmi les pixels de l’objet  $O$ , de la classe  $C$  ( $S_O^{int*} \subset O$ ) et un parmi les pixels de l’image hors de la classe en cours ( $S_O^{hc*} \subset I \setminus \mathcal{I}(C)$ ), définissant ainsi un ensemble d’apprentissage  $S_O^* = \{S_O^{int*}, S_O^{hc*}\}$ . Ces deux sous-ensembles sont choisis parmi plusieurs sous-ensembles de pixels tirés au hasard, en cherchant à maximiser le rappel de la classification (classe / hors-classe). La sélection de l’ensemble d’apprentissage est effectuée en deux étapes : (1) le choix du meilleur sous-ensemble *intérieur* et (2) le choix du



meilleur sous-ensemble *hors-classe*. L'ensemble *intérieur* est choisi en premier, car l'objet est plus uniforme et plus petit que l'*extérieur*, et donc le choix sera plus stable que pour celui de l'ensemble *extérieur*. Cependant, plusieurs itération entre le choix de l'ensemble *intérieur* puis *extérieur* pourraient améliorer le processus.

Dans un premier temps, un sous-ensemble de pixels *hors-classe*, est tiré aléatoirement hors de la classe de l'objet courant,  $S_O^{hc} \subset I \setminus \mathcal{I}(C)$ . Ces pixels peuvent appartenir à une autre classe ou ne correspondre à aucune classe de la BD. Par suite,  $N_{int}$  sous-ensembles *intérieurs* sont également tirés aléatoirement parmi les pixels qui composent l'objet courant :

$$\{S_O^{int_j}\}_{j \in [1..N_{int}]} \subset O^{N_{int}}. \quad (6.3)$$

Un classifieur est obtenu sur chacun des sous-ensembles *intérieurs* couplé à l'ensemble *hors-classe*,  $\{l_c^{int_j}\}_{j \in [1..N_{int}]}$ . Le rappel de chaque classifieur sur la classe *intérieure* ( $C_{int}$ ) est calculé en utilisant les pixels de l'objet comme vérité terrain, *i.e.*,  $VT = \{\mathcal{I}(O), L_{BD}\}$ . Le sous-ensemble *intérieur*  $int^*$  maximisant le rappel de la classification est ainsi choisi.

$$int^* = \arg \max_{j \in [1..N_{int}]} Rappel(l_c^{int_j}, VT, C_{int}). \quad (6.4)$$

Dans un second temps, le sous-ensemble optimal *hors-classe*  $hc^*$  est choisi de façon identique, en tirant aléatoirement  $N_{hc}$  sous-ensembles *hors-classe* (le premier ensemble correspondant à celui tiré à l'étape précédente :  $S_O^{hc_1} = S_O^{hc}$ ), définissant autant de classifieurs  $\{l_c^{int^*, hc_j}\}_{j \in [1..N_{hc}]}$  :

$$\{S_O^{int^*, hc_j}\}_{j \in [1..N_{hc}]} \subset (I \setminus \mathcal{I}(C))^{N_{hc}}, \quad (6.5)$$

$$hc^* = \arg \max_{j \in [1..N_{hc}]} Rappel(l_c^{int^*, hc_j, C_{int}}, VT). \quad (6.6)$$

L'ensemble d'apprentissage optimal est finalement défini par l'union des deux meilleurs sous-ensembles *intérieur*  $S_O^{int^*}$  et *hors-classe*  $S_O^{hc^*}$ .

$$S_O^* = S_O^{int^*} \cup S_O^{hc^*}. \quad (6.7)$$

Une étude qualitative a permis de fixer le nombre de points d'apprentissage à 200 (100 *intérieurs* et 100 *hors-classe*) et le nombre de tirages successifs  $N_{int}$  et  $N_{hc}$  à 10. Cependant, la taille de l'ensemble d'apprentissage devra être augmentée avec le nombre d'attributs utilisés (*cf.* sous-section 5.2.1). De plus, une étude quantitative sur le nombre de tirages  $N_{int}$  et  $N_{hc}$  devra être menée, en particulier pour voir si ces valeurs optimales varient d'une zone géographique à une autre.

## Classification

L'ensemble d'apprentissage optimal  $S_O^*$ , associé à l'objet  $O$  est alors utilisé pour entraîner un classifieur  $l_O$  et ainsi, obtenir une probabilité d'appartenance de chaque pixel de l'image à la classe courante, *i.e.*, une carte de probabilité  $\mathcal{P}_O$ . Les probabilités sont issues du classifieur choisi (*cf.* sous-section 7.1.3 dans le chapitre suivant).

$$\mathcal{P}_O = \mathcal{P}(S_O^*) = \mathcal{P}(S_O^{int*}, S_O^{e*}). \quad (6.8)$$

### 6.2.2 Niveau classe

Les cartes de probabilités  $\mathcal{P}_O$ , obtenues pour chaque objet  $O$  d'une classe  $C$  donnée, sont fusionnées afin d'obtenir une seule carte de confiance par classe  $\mathcal{P}^C$  (Équation 6.9). Cette carte définit, pour chaque pixel de l'image, une probabilité d'appartenance de ce pixel à la classe en cours. La fusion au niveau de chaque classe permet de prendre en compte les différentes apparences d'une classe. Cependant, cette étape pourrait être omise en introduisant à l'étape suivante, un processus de prise de décision prenant en compte les probabilités d'appartenance à chaque objet, par exemple en introduisant une étape de classification [Waske et Benediktsson, 2007].

$$\mathcal{P}^C = \text{Fusion}(\{\mathcal{P}_O, \quad O \in C\}). \quad (6.9)$$

Différentes méthodes de fusion ont été décrites dans la sous-section 5.3.2. Nous avons choisi dans un premier temps d'utiliser la moyenne des probabilités (Équation 6.10) pour valider la méthode théorique (*cf.* 6.3) Le choix d'une méthode de fusion plus performante est discuté dans la sous-section 7.1.4 du chapitre suivant.

$$\mathcal{P}_{moy}^C = \frac{1}{\#C} \sum_{O \in C} \mathcal{P}_O. \quad (6.10)$$

### 6.2.3 Niveau base de données

L'ensemble des probabilités d'appartenance à chaque classe ( $\mathcal{P}^C$ ) est utilisé pour obtenir la classe d'appartenance de chaque pixel de l'image, ainsi qu'une carte de confiance dans la classification obtenue. Puis, une carte de probabilité de changement est obtenue par comparaison de la nouvelle classification avec la BD existante.

## Prise de décision et carte de confiance

A l'image des méthodes de fusion par vote majoritaire (*cf.* 5.3.2), la classification finale est obtenue en gardant, pour chaque pixel de l'image, la classe

ayant la plus forte probabilité, calculée à l'étape précédente. Elle est définie par la fonction suivante :

$$\begin{aligned} L_{C_1} : I &\longrightarrow [1..N_C] \\ p &\longmapsto \arg \max_{j \in [1..N_C]} \mathcal{P}^{C_j}(p) \end{aligned} \quad (6.11)$$

Cette prise de décision permet de dégager deux données complémentaires : (1) la BD mise à jour sur son emprise initiale et (2) la complétion de la BD sur le reste de l'image. En effet, l'*extérieure* de la BD initiale est également classé à cette étape.

Une valeur de confiance ( $Co$ ) est associée à cette classification ( $L_{C_1}$ ), elle permettra de mettre en évidence les zones d'ambiguïté. En pratique, la valeur maximale des probabilités de chaque classe  $Co_{max}$  donne une mesure de confiance dans la classification précédente :

$$\begin{aligned} Co_{max} : I &\longrightarrow [0, 1] \\ p &\longmapsto \mathcal{P}^{C_{L_{C_1}(p)}}(p) \end{aligned} \quad (6.12)$$

Cependant, si plusieurs classes ont des probabilités importantes, leurs valeurs maximales sont fortes, alors que la confiance devrait être faible. Car, dans ce cas, il y a un risque de confusion entre les deux classes ayant de fortes probabilités. Ainsi, une autre mesure, appelée la *marge*, est proposée. Cette mesure est définie comme la différence entre les deux plus fortes valeurs de probabilités, relatives à  $L_{C_1}$  (la plus forte valeur) et  $L_{C_2}$  (la deuxième plus forte valeur).

$$\begin{aligned} Co_{marge} : I &\longrightarrow [0, 1] \\ p &\longmapsto \mathcal{P}^{C_{L_{C_1}(p)}}(p) - \mathcal{P}^{C_{L_{C_2}(p)}}(p), \end{aligned} \quad (6.13)$$

où  $L_{C_2}(p)$  est la classe ayant la deuxième probabilité la plus forte en  $p$ .

Nous avons décidé de choisir cette seconde valeur pour mesurer la confiance dans la prise de décision au niveau de la BD :

$$Co = Co_{marge}. \quad (6.14)$$

## Carte de probabilité de changement

Une carte de changement  $\Delta$  est obtenue par comparaison de la classification et de la BD d'origine. Chaque pixel peut ainsi prendre, soit la valeur -1 (changement) soit la valeur 1 (non-changement).

$$\forall p \in I, \quad \Delta(p) = \begin{cases} -1 & \text{si } L_{C_1}(p) \neq L_{BD}(p) \\ 1 & \text{si } L_{C_1}(p) = L_{BD}(p) \end{cases} \quad (6.15)$$

La carte de changement  $\Delta$  est alors pondérée par la mesure de confiance  $Co$  de l'étape précédente, afin d'obtenir une carte de confiance, pouvant être interprétée comme une carte de probabilité de changement  $\Pi$ .

$$\forall p \in I, \quad \Pi(p) = \Delta(p) \times Co(p). \quad (6.16)$$

Par suite, cette dernière est séparée en trois classes : changement certain, non-changement certain et indécision (devant correspondre aux zones d'incertitude). Pour cela, deux seuils doivent être introduits, ils permettront de trouver un compromis entre le taux de bonne classification et le nombre de fausses alertes tolérées. Ainsi, plus les seuils auront de fortes valeurs ( $seuil_1 \rightarrow -1$  et  $seuil_2 \rightarrow 1$ ), moins la classification comportera d'erreurs, mais plus la zone d'indécision sera grande. Un opérateur devra donc inspecter manuellement une zone d'indécision plus étendue. À l'inverse, plus les seuils seront faibles ( $seuil_1 \rightarrow 0$  et  $seuil_2 \rightarrow 0$ ), plus la zone d'indécision sera réduite (l'opérateur aura moins de polygones à inspecter), mais la classification pourra contenir plus d'erreurs. La sensibilité de ces deux paramètres dépendra grandement de la réussite des classifications. En effet, si les classifications sont confiantes, alors une variation des seuils aura peu d'influence sur l'étendue géographique de la zone d'indécision.

$$\forall p \in I, \quad \begin{cases} \text{changement certain} & \text{si } \Pi(p) \leq \text{seuil}_1 \\ \text{non-changement certain} & \text{si } \Pi(p) \geq \text{seuil}_2 \\ \text{indécision} & \text{sinon} \end{cases} \quad (6.17)$$

La classification permet de focaliser un opérateur sur les zones de changement, ou sur les zones d'incertitude. Dans la suite de notre travail, nous chercherons à améliorer les classifications et leurs fusions afin de réduire le plus possible la classe indécision.

## 6.3 Validation théorique de la méthode

Dans cette partie, nous présentons plusieurs expérimentations permettant de valider la partie théorique de la méthode MLMOL sur un jeu de données simulées. Ces données simulées permettent d'étudier le comportement de la méthode en restant indépendant des caractéristiques utilisées pour décrire les objets de la BD. Le jeu de données simulées est décrit dans un premier temps, puis différentes expérimentations sont menées sur ces données, afin de tester la robustesse de la méthode à des classes ayant des apparences semblables, à des classes inhomogènes et à des données floutées.

### 6.3.1 Présentation des données simulées

Le jeu de données simulées est composé de deux parties : (1) la *BD initiale* (à mettre à jour), (2) l'*image simulée* (utilisée pour mettre à jour la BD).

La *BD initiale* est composée de 10 classes elles-mêmes composées de 10 objets de même taille et de même forme. Les objets sont répartis sur une grille régulière car l'arrangement spatial n'intervient pas dans notre processus de décision. Chaque objet (carré) fait 100 pixels de côté. Pour simplifier la visualisation, la *BD initiale* est représentée par une image (Figure 6.4a), chaque classe est représentée par un niveau de gris différent et suffisamment éloigné, car on n'étudie pas ici le comportement des attributs. La zone bleu-grise en bord d'image (colonnes 0 & 11 et lignes 0 & 11) correspond à une zone non étiquetée dans la *BD initiale* (*extérieur*).

L'*image simulée* est composée de 101 objets de tailles variables (Figure 6.4b). Différents types de changements sont introduits entre la *BD initiale* et l'*image simulée* : la disparition d'une partie ou de la totalité de l'objet (ligne 3), l'apparition d'un objet (ligne 11), le changement de classe d'une partie de l'objet (lignes 1 et 2 de la Figure 6.4c). Quatre objets disparaissent et quinze apparaissent. Les objets de chaque ligne changent de la même manière, dans des proportions croissantes (de 10 à 100 %). Les changements de chaque classe représentent entre 10 et 30 % de la surface de l'image. Cette configuration permettra de valider notre méthode face aux différents types de changements existants. Par ailleurs, la connaissance de la vérité terrain permettra de qualifier l'ensemble des résultats obtenus par la suite.

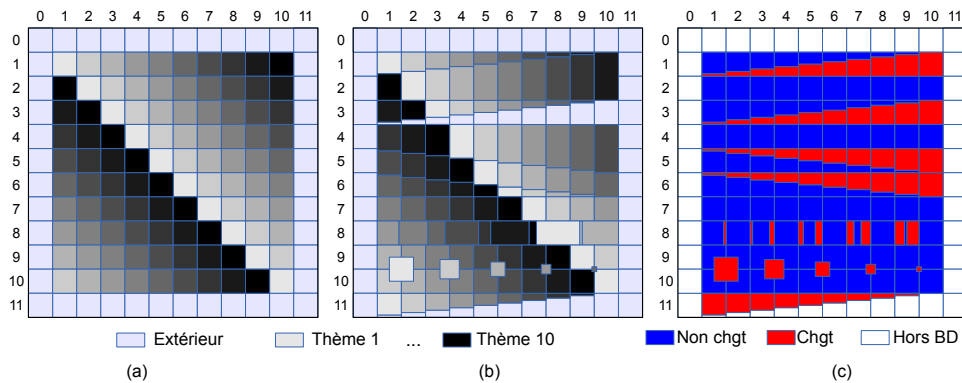


FIGURE 6.4 – Présentation des données simulées : (a) la *BD initiale* (à mettre à jour), (b) l'*image simulée* (utilisée pour mettre à jour la BD) et (c) la carte des changements (vérité terrain). Chaque cellule  $(i, j)$  fait  $100 \times 100$  pixels.

### 6.3.2 Expérimentations

Quatre expériences ont été menées sur les données simulées. La méthode MLMOL est d'abord appliquée sur les données simulées sans modifier ces dernières, afin de fournir une référence pour comparer les autres expériences. Puis, trois types de modifications sont introduits sur l'*image simulée* afin de tester la robustesse de la méthode :

- à des classes similaires ;
- à des classes in-homogènes ;
- à des données floutées.

Dans l'ensemble de ces expérimentations, les classifications sont réalisées par un SVM, avec un noyau gaussien (*cf.* 5.2.2).

## Conditions idéales

Dans un premier temps, les trois niveaux d'inspection décrits précédemment sont évalués sur les données simulées idéales (Figure 6.4b).

La BD est inspectée au niveau des objets. Le rappel et la précision de la classification sont calculés sur chaque objet de chaque classe de la BD. Dans ces conditions parfaites (un niveau de gris par classe suffisamment éloigné) le rappel est toujours égal à 1. Cependant, la précision peut être différente de 1. En effet, si la taille d'un objet diminue (*e.g.*, chaque objet de la ligne 1), la classification va confondre la classe de l'objet courant avec la classe remplaçante. Ainsi, la précision prendra des valeurs plus faibles, comprises entre 0,21 et 0,6, selon la surface totale de la classe remplaçante (respectivement de 10 à 30 % de l'image).

Malgré certaines confusions introduites au niveau objet, la fusion au niveau des classes et la prise de décision au niveau de la BD a permis de labelliser correctement (à 100 %) l'ensemble des classes (Figure 6.5 a). Ainsi, la redondance d'information introduite par la multiplication des classifications permet de compenser d'éventuels problèmes sur les classifications individuelles. Cependant, il n'y a pas de classe *extérieure* dans la classification, alors qu'elle existe sur l'*image initiale*. Ainsi, la méthode confond les objets non-étiquetés (*extérieur*) avec la classe ayant le niveau de gris le plus proche. Toutefois, les deux mesures de confiance, la probabilité maximale (Figure 6.5b) et la marge (Figure 6.5c), ont de faibles valeurs dans cette zone. De plus, ces mesures de confiance ont des valeurs différentes suivant les classes, montrant des surfaces de changement de tailles différentes. Ainsi, la classification sur la carte de probabilité de changement (Figure 6.6a) permet de séparer correctement les vraies zones de changement / non changement, des zones d'incertitude avec des seuils relativement souples (entre 0,18 et 0,86 pour la mesure calculée à partir de la probabilité maximale et entre 0,05 et 0,4 pour celle fondée sur la marge).

Enfin, une mesure de la précision est proposée pour évaluer quantitativement les résultats en supprimant l'effet introduit par les pixels *extérieurs*. Pour cela, la carte de probabilité de changements est seuillée à deux niveaux pour obtenir trois classes : changement, hors de la BD et non-changement (Figure 6.6f). Nous avons utilisé deux seuils fixés à  $-0,2$  et  $0,2$ , permettant d'être au plus proche de la limite inférieure obtenue précédemment (0,18). Puis la classification est comparée à la vérité terrain (Figure 6.4c). La mesure de précision obtenue dans ce cas idéal est de 100 %.




FIGURE 6.5 – Résultats sur le données simulées dans les conditions idéales : (a) Fusion des classes, (un niveau de gris par classe), (b) Probabilité maximale et (c) Marge (■ : 0  $\rightarrow$  □ : 1). Chaque pixel est correctement labellisé (a), sauf sur les zones extérieures où (b) et (c) ont de faibles valeurs.

### Classes similaires

Dans un second temps, nous avons étudié la capacité de la méthode MLMOL à séparer deux classes ayant des apparences proches. Pour cela, les classes 3 et 4 ont été choisies. Leurs niveaux de gris sont respectivement égaux à 179 et 153. La valeur de la classe 3 a été itérativement remplacée par des valeurs comprises entre 169 et 153, pour se rapprocher de la classe 4 (dans le dernier cas, les deux classes sont identiques, donc non séparables).

L'étape de classification permet de séparer correctement les classes 3 et 4, sauf quand ces deux classes ont exactement la même valeur. La Figure 6.6 (b) montre la carte de probabilité de changement résultant de notre méthode, lorsque les deux classes 3 et 4 ont des valeurs proches mais différentes (valeur de niveau de gris de 154 et 153) et la Figure 6.6 (c) quand ces deux classes ont la même valeur. La précision obtenue est de 80 % quand les classes 3 et 4 sont identiques. En effet, les classifications sur les classes 3 et 4 sont similaires, donc la confusion est grande, ainsi les surfaces correspondantes sont marquées comme indécises. Dans les autres cas, les classes sont séparables et les résultats sont identiques au cas idéal (précision de 100 %). Ainsi, les résultats montrent que notre méthode permet de gérer correctement des classes d'apparences similaires en introduisant une mesure de confiance en plus de la classification.

### Classes in-homogènes

La troisième expérience a pour objectif de déterminer si la méthode MLMOL est sensible à des classes in-homogènes. En effet, certaines classes peuvent avoir plusieurs apparences différentes (intra objets). Ceci arrive régulièrement dans les BDs géographiques quand un objet inclut plusieurs entités avec des caractéristiques différentes (*e.g.*, champs partiellement labourés, prairie dans une forêt, textures, différentes conditions d'illumination ...). Ainsi, nous avons sélectionné



les trois mêmes classes que dans l'expérience précédente et nous avons appliqué deux valeurs différentes aux pixels des objets de la classe 3 (deux sous-classes). Dans une première configuration, les deux valeurs de niveaux de gris restent entre les valeurs des classes 2 et 4 (166 / 191), dans la seconde, les valeurs sont en dehors de cet intervalle (140 / 217). Enfin, les proportions de chacune des deux valeurs (166 / 191 ou 140 / 217) ont été modifiées de 10 à 50 % (une valeur supérieure à 50 % d'une sous-classe correspondant à une valeur inférieure à 50 % de l'autre sous-classe).

Pour une proportion de 10 %, la précision est de 99 % dans les deux configurations et de 100 % dans les autres cas. Ceci peut-être expliqué par le fait qu'il est plus difficile d'apprendre l'apparence de la sous-classe la moins représentée. Les résultats montrent que notre méthode de sélection des points d'apprentissage permet de résoudre le problème des classes in-homogènes, même dans le cas où un faible pourcentage de la classe est différent du reste de cette dernière. De plus, l'utilisation d'un noyau gaussien dans la classification par SVM permet de différencier la classe 3 des autres classes, même si elle n'est pas linéairement séparable. Enfin, la carte de probabilité de changement (Figure 6.6 d) permet de discriminer correctement les zones de changement et de non changement (zones *bleue/rouge*). En effet, les valeurs de confiance des deux sous-classes de la classe in-homogène sont peu différentes, ainsi les probabilités de changements résultantes sont semblables et permettent de prendre la bonne décision (changement / non-changement) sur l'ensemble de la classe.

### Données floutées

Les contours des objets vus sur les images satellite peuvent être mal définis, par exemple de l'ombre peut exister à la transition entre champs et forêts, ou la frontière entre une forêt ouverte et une forêt fermée est difficile à définir. Ainsi la dernière expérience cherche à prouver l'efficacité de notre méthode sur des données floutées. Un filtre gaussien, de  $\sigma$  croissant (entre  $\sqrt{5}$  et 10 pixels), est appliqué sur l'image simulée.

La précision des résultats varie entre 88 % (pour  $\sigma = 10$  pixels) à 98 % (pour  $\sigma = \sqrt{5}$  pixels). Dans ce cas, la classification au niveau de l'objet et la fusion par classe sont moins précises que dans les conditions idéales. Cependant, notre méthode de sélection des points d'apprentissage permet d'obtenir des résultats satisfaisants. Enfin, la carte de probabilité de changement (Figure 6.6 e) permet quand même de distinguer la majorité des vrais changements.

## 6.4 Conclusion

Dans ce chapitre, une méthode simple et générique de mise à jour et de détection de changement, MLMOL, a été présentée puis validée sur des données simulées. Cette méthode fournit trois informations complémentaires : (1) une carte de probabilité de changements, permettant de focaliser le travail d'un opé-

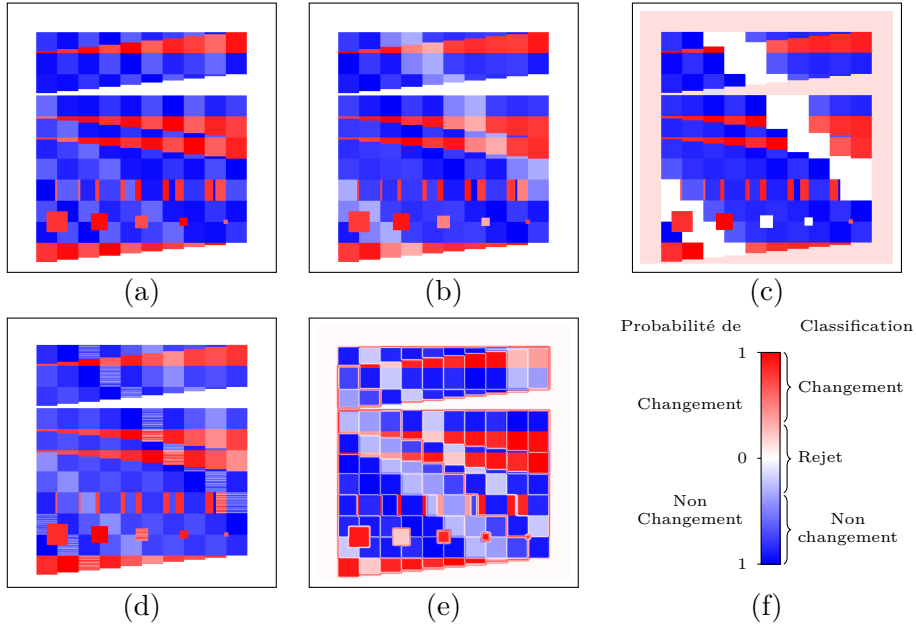


FIGURE 6.6 – Carte de probabilité de changement pour l’ensemble des expériences : (a) Condition idéale, (b) deux classes similaires, (c) deux classes identiques, (d) une classe in-homogène et (e) données floutées. Les zones bleu foncé correspondent aux zones sans changement, alors que les zones rouges correspondent aux zones de changement. Les zones blanches correspondent aux zones de confusion. L’échelle de probabilité de changements (f) est classée en changement / non changement. Une classe de rejet correspondant aux zones hors de la BD a été rajoutée.

rateur sur les zones de changements ou les zones d'incertitudes ; (2) une mise à jour de la BD initiale sur sa zone de couverture et (3) une complétion de cette BD sur le reste de l'image.

La méthode MLMOL permet d'apprendre l'apparence de chacune des classes composant la BD malgré un apprentissage sur des données imparfaites (l'image contient des changements par rapport à l'ancienne BD).

Les expérimentations ont également montré la robustesse de la méthode face à des classes similaires ainsi qu'à des classes in-homogènes. De plus, l'indépendance aux attributs de classifications et à la méthode de classification permet d'envisager l'application de cette méthode à différentes problématiques.

De plus, dans le cas de l'initialisation d'une nouvelle BD, obtenue à partir de différentes BDs existantes, la méthode MLMOL permet : (1) de compléter les zones non couvertes par les BDs initiales et (2) d'aider à la prise de décision en cas de superposition des BDs initiales.

Le chapitre suivant s'intéressera à l'adaptation de la méthode proposée pour la mise à jour de BD d'OCS à partir d'images satellite THR, notamment en terme d'attributs de classifications, de fusion de classifications et de passage à l'échelle. Ainsi, la méthode MLMOL sera inscrite dans la chaîne de traitement I<sup>2</sup>P<sup>2</sup>N.



# Intégration de la méthode ML-MOL dans la chaîne de traitements LUPIN

---

## Sommaire

---

<b>8.1</b>	<b>Jeu de données . . . . .</b>	<b>116</b>
8.1.1	Image satellite . . . . .	116
8.1.2	Occupation du sol . . . . .	116
<b>8.2</b>	<b>Résultats sur OCS simplifiée . . . . .</b>	<b>120</b>
<b>8.3</b>	<b>Résultats sur OCS-GE . . . . .</b>	<b>121</b>
8.3.1	Étude chiffrée des classifications . . . . .	123
8.3.2	Étude visuelle . . . . .	124
8.3.3	Résultats supplémentaires . . . . .	129
<b>8.4</b>	<b>Étude des temps de traitements . . . . .</b>	<b>135</b>
<b>8.5</b>	<b>Conclusion . . . . .</b>	<b>136</b>

---

Une méthode générique de mise à jour de base de données, appelée MLMOL, est proposée dans le chapitre précédent. L’objet de ce chapitre est l’intégration de cette méthode dans une chaîne de traitement globale, nommée Land-cover databases Updating by Processing Images in Natural environment (LUPIN), permettant de s’adapter aux données d’OCS et aux images satellites THR. Cette chaîne de traitement s’appuie sur des méthodes de l’état-de-l’art, en terme de calcul d’attributs, de sélection d’attributs et de classification, qui sont adaptées à notre problématique. Ce chapitre est divisé en deux sections. Dans un premier temps, les étapes introduites dans la chaîne de traitements et les améliorations apportées à la méthode générique pour l’adaptation aux données, la polyvalence et le passage à l’échelle, sont présentées dans la section 7.1. Chacun des éléments introduits est qualifié individuellement à l’aide de différentes expérimentations menées sur un jeu de données générées à partir de parties d’images Pléiades. Dans un second temps, la chaîne de traitements LUPIN ainsi adaptée est validée et comparée à deux méthodes de classification de l’état-de-l’art sur le même jeu de données générées (section 7.2).

## 7.1 Intégration de MLMOL dans la chaîne LUPIN

L’intégration de la méthode MLMOL dans la chaîne de traitements LUPIN a nécessité différentes adaptations (*cf.* Figure 7.1) prenant en compte les observations faites dans la Partie II. Dans un premier temps, on cherche à extraire le plus d’informations possible des images THR à notre disposition afin de discriminer au mieux les classes composant la BD à mettre à jour (sous-section 7.1.1). Puis, une étape de sélection d’attributs permet de réduire les temps de classification tout en évitant les problèmes liés à l’utilisation d’un trop grand nombre d’attributs (sous-section 7.1.2). Les choix des méthodes de classification et de fusion des classifications sont discutés dans les sous-sections 7.1.3 et 7.1.4. Enfin, plusieurs propositions sont faites dans la sous-section 7.1.5 afin d’aller vers un passage à l’échelle nécessaire pour traiter des surfaces importantes (départements ou régions).

### 7.1.1 Extraction d’attributs

La méthode LUPIN nécessite de pouvoir discriminer au mieux chacune des classes de la BD des autres classes de cette BD. Or, nous avons pu voir dans le chapitre 3, d’une part qu’un grand nombre d’attributs existent dans la littérature, et d’autre part que les attributs les plus discriminants varient beaucoup suivant les classes étudiées et les images dont on dispose. Ainsi, nous avons décidé de calculer un grand nombre d’attributs de natures différentes (15 attributs spectraux, 728 attributs de texture et 160 attributs morphologiques) afin d’adapter la méthode aux différentes classes pouvant être présentes dans la BD OCS considérée (*cf.* Tableau 7.1). Ces attributs ont été choisis pour leur polyvalence, leur utilisation fréquente dans le domaine de la télédétection et la disponibilité

# LUPIN

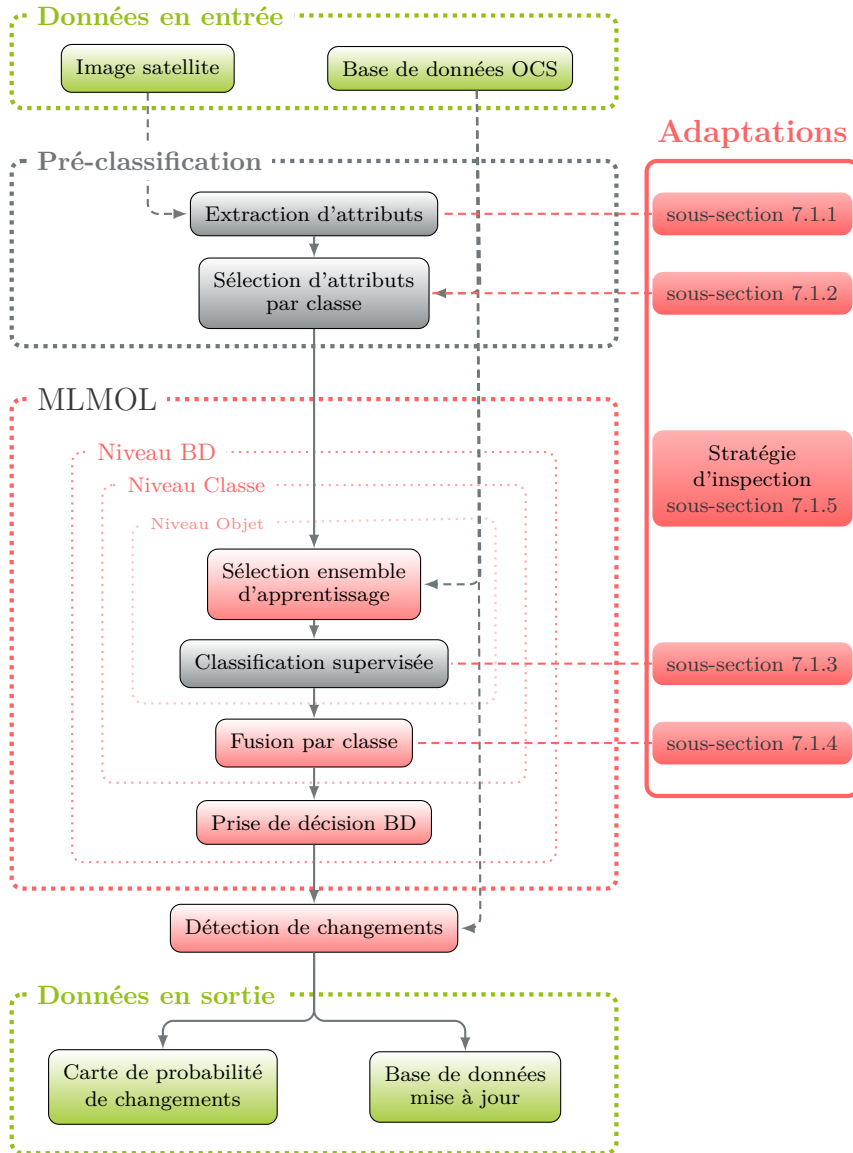


FIGURE 7.1 – Schéma des adaptations apportées à la méthode générale.



de leur implémentation. Cependant, certains attributs très classiques, comme les ondelettes, n'ont pas été utilisés, car les temps de traitement sur notre jeu de données devenaient trop importants. Cependant, ces attributs peuvent être intégrés facilement dans la méthode.

Les caractéristiques utilisées sont calculées à partir des outils développés au sein du laboratoire MATIS [Trias-Sanz et al., 2008], les bibliothèques Orfeo-ToolBox [Inglada et Christophe, 2009] et colorDescriptor [van de Sande et al., 2010], ainsi que les outils de Dalla Mura et al. [2010].

### 7.1.2 Sélection d'attributs

Présentée dans le chapitre 4, la sélection d'attributs est une étape clé de la réussite d'une classification. En effet, elle permet d'améliorer conjointement la performance de la classification en évitant la malédiction de la dimension et la rapidité des traitements en diminuant la complexité des calculs réalisés. Or, dans la méthode MLMOL, un grand nombre de classifications, de type « un-contre-tous » est réalisé. Ainsi, l'ajout d'une étape de sélection d'attributs est d'une grande utilité. De plus, nous avons décidé de réaliser une sélection d'attributs au niveau de la nomenclature (une sélection par classe) et non pas pour chaque objet de la BD. Ainsi, l'ensemble des classifications d'une classe de la BD repose sur un sous-ensemble commun d'attributs, qui permet de discriminer au mieux cette classe du reste des classes de la BD. Comme indiqué dans la conclusion du chapitre 4, notre choix s'est porté sur l'importance des attributs des FAs.

Par ailleurs, l'importance des attributs des FAs, présentée dans le chapitre 5 permet de juger de la qualité d'un attribut pour la classification d'une classe particulière de la BD, et ainsi de limiter le calcul d'un nombre important d'attributs qui n'est pas envisageable sur de grands volumes de données (*e.g.*, images Pléiades sur un département). Dans cette optique, nous avons étudié sur un jeu de données généré (*cf.* 7.2.1) l'importance des attributs calculés à partir de l'ensemble des attributs disponibles (Figure 7.2).

Ainsi, tous les attributs décrits dans le Tableau 7.1 sont utilisés. Puis, pour chaque classe composant la BD générée, décrite dans la sous-section 7.2.1, une classification de type « un-contre-tous » est réalisée avec l'algorithme des FAs.

Les importances des attributs issues de ce calcul sont rassemblées dans la Figure 7.2. Afin d'améliorer la visibilité, les attributs sont regroupés par familles :

- AP pour les profils d'attributs (morphologiques) ;
- CD pour les attributs issus de la bibliothèque colorDescriptor ;
- HK-c pour les attributs d'Haralick calculés sur le canal c (parmi les canaux R, V, B, IR et P) ;
- SP pour les attributs spectraux.

De manière générale, les attributs morphologiques (AP), les attributs de textures Haralick calculés sur les canaux IR et P (HK-ir, HK-p), ainsi que les attributs spectraux (SP) ressortent dans une grande majorité des classes. D'autre part, des thèmes complexes, comme les *Forêts non-discriminées* ou les *conifères*,

<b>Attributs Spectraux (SD)</b>			
Nom	Dimension	Canaux d'origine	Librairie
GEMI	1	RVB-IR	otb
IPVI	1	RVB-IR	otb
MSAVI	1	RVB-IR	otb
MSAVI2	1	RVB-IR	otb
NDVI	1	RVB-IR	otb
RVI	1	RVB-IR	otb
SAVI	1	RVB-IR	otb
TNDVI	1	RVB-IR	otb
TSAVI	1	RVB-IR	otb
BI	1	RVB-IR	otb
BI2	1	RVB-IR	otb
RI	1	RVB-IR	otb
NDWI2	1	RVB-IR	otb
<b>Attributs de Textures</b>			
Nom	Dimension	Canaux d'origine	Librairie
SFS	6	P	otb
Pix-ent-c	1	P	AVET
Haralick (HK)			
Haralick Simple	$5 \times 5 \times 8$	P RVB-IR	otb
Haralick Avanced	$5 \times 5 \times 9$	P RVB-IR	otb
Haralick Higher	$5 \times 5 \times 11$	P RVB-IR	otb
ColorDescriptor (CD)			
Colormomentinv	3	RVB	colorDescriptor
Colormoments	3	RVB	colorDescriptor
HueHisto	3	RVB	colorDescriptor
NrgHisto	3	RVB	colorDescriptor
OpponentHisto	3	RVB	colorDescriptor
RgbHisto	3	RVB	colorDescriptor
TranscolorHisto	3	RVB	colorDescriptor
<b>Attributs Morphologiques (AP)</b>			
Nom	Dimension	Canal d'origine	Librairie
AP-p	$2 \times 4 \times 4$	P	Dalla Mura
AP-r	$2 \times 4 \times 4$	R	Dalla Mura
AP-v	$2 \times 4 \times 4$	V	Dalla Mura
AP-b	$2 \times 4 \times 4$	B	Dalla Mura
AP-ir	$2 \times 4 \times 4$	IR	Dalla Mura

Tableau 7.1 – Tableau récapitulatif de l'ensemble des 901 attributs calculés à partir des cinq canaux de l'image (P : panchromatique, R : rouge, V : vert, B : bleu et IR : infra-rouge) : 13 attributs spectraux, 728 attributs de textures et 160 attributs morphologiques.

nécessitent un plus grand nombre d'attributs (l'importance de chaque attribut est plus faible) que des classes simples comme l'*eau*. Certaines familles d'attributs ne sont pas très discriminantes et peuvent donc être mises à l'écart, c'est le cas en particulier des attributs de textures Haralick calculés sur les canaux R, V et B. Par ailleurs, une étude détaillée par famille d'attributs est disponible en annexe de ce document (*cf.* Tableau A).

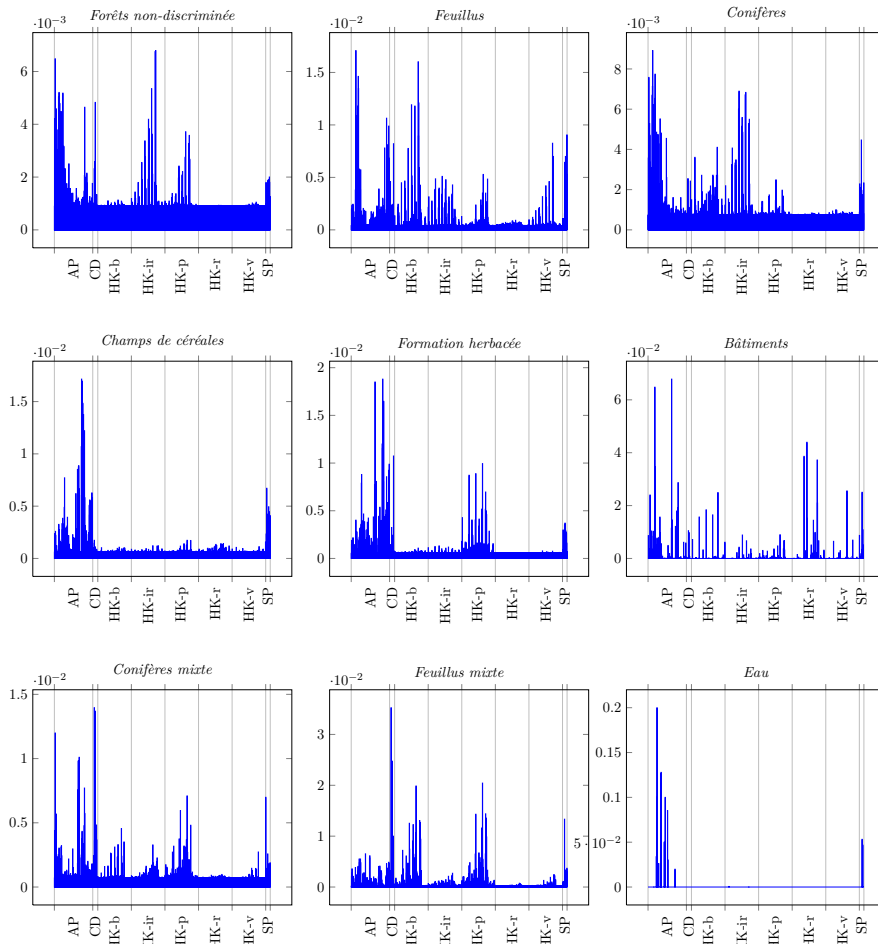


FIGURE 7.2 – Importance des attributs par classe de la BD-OCS, par utilisation des FAs.

L'influence du nombre d'attributs sélectionnés est discutée dans le paragraphe suivant. En effet, nous verrons que les paramètres de la sélection d'attributs dépendent fortement du classifieur choisi et qu'un nombre de 20 attributs par thèmes pour une classification par FA est raisonnable.

Enfin, dans le cas de la sélection des 20 meilleurs attributs de chaque thème (soit 180 attributs ici), nous avons obtenu seulement 123 attributs uniques. La répartition de ces attributs par famille d'attributs est décrite dans le Tableau 7.2.

Famille d'attributs	AP	CD	HK-b	HK-ir	HK-p	HK-r	HK-v	SP
Nombre d'attributs sélectionnés	63	5	19	11	10	5	4	6

Tableau 7.2 – Nombre d'attributs uniques sélectionnés sur l'ensemble des thèmes par famille d'attributs.

Ainsi, les attributs morphologiques sont les attributs les plus représentés dans cette sélection (63/126). À l'inverse, les attributs CD ne sont sélectionnés que 5 fois. 49 attributs de texture HK et 6 attributs spectraux (SP) sont sélectionnés. En proportion d'attributs sélectionnés par famille, les attributs spectraux (2 sur 19 calculés) et les attributs CD (5 sur 21) sont les plus représentés, viennent ensuite les attributs morphologiques AP (62 sur 120). Les attributs de texture Haralick (HK) sont proportionnellement les moins représentés (49 sur 700).

### 7.1.3 Choix du classifieur

La méthode MLMOL repose sur l'utilisation d'un classifieur binaire supervisé. De plus, cette méthode de classification doit permettre de :

- 1) gérer un grand nombre de caractéristiques,
- 2) d'avoir une grande capacité de généralisation,
- 3) d'être assez rapide pour effectuer dans un temps raisonnable le nombre important de classifications nécessaires dans notre méthode ;
- 4) de fournir une information sur la confiance de la classification (ou probabilité d'appartenance à la classe).

Comme nous avons pu le constater dans le chapitre 5, différentes méthodes de classification supervisée existent. Parmi celles-ci, deux méthodes sont couramment utilisées et respectent les critères cités ci-dessus : les SVMs et les FAs. Nous avons donc décidé de comparer ces deux méthodes sur notre jeu de données générées (*cf.* sous-section 7.2.1) afin de juger de leur pertinence. Pour les SVMs, un noyau gaussien est utilisé, car il est réputé pour donner de très bons résultats de classification sur des attributs complexes (*cf.* section 5.2.2). Les paramètres ( $C$ ,  $\gamma$ ) du noyau sont choisis afin de maximiser la précision par validation croisée (par découpage de l'ensemble d'apprentissage en 4 sous-ensembles), en utilisant une méthode de recherche par grille. La probabilité d'appartenance d'un pixel à la classe en cours d'analyse est fournie par la méthode décrite précédemment (section 5.2.2). De leur côté, les FAs fournissent une mesure de confiance dans la classification grâce à la marge (*cf.* section 5.2.2).

Afin de comparer ces deux méthodes en terme de qualité de classification et de rapidité de calcul, nous avons réalisé l'expérience suivante. Dans un premier temps, pour chaque classe de la BD des données générées, les 901 attributs décrits dans la sous-section 7.1.1 ont été rangés par ordre décroissant d'importance (fournis par l'importance des attributs des FAs). Puis, des classifications de type « un-contre-tous » ont été réalisées avec un nombre croissant d'attributs (introduit dans l'ordre précédent). La variation du taux de bonne classification

(précision globale) et de la vitesse de calcul, moyennée sur l'ensemble des classifications (dix par classe), en fonction du nombre d'attributs, ainsi obtenue, est présentée dans la Figure 7.3. Dans un premier temps, nous pouvons observer une courbe classique : la précision globale augmente avec le nombre d'attributs jusqu'à un maximum, puis la précision diminue, c'est la malédiction de la dimension évoquée dans le chapitre 4. Par ailleurs, sur notre jeu de données, l'expérience montre un grand avantage des FAs sur deux points. Premièrement, bien que les deux méthodes donnent des résultats similaires avec un faible nombre d'attributs (inférieur à 7), les FAs ont un meilleur taux de bonne classification que les SVMs dès que le nombre d'attributs est supérieur à cette valeur. Enfin, le temps de calcul des FAs, qui est bien inférieur à celui des SVMs, n'augmente que très peu quand le nombre d'attributs augmente. Alors que le temps de calcul des SVMs croît très rapidement avec l'augmentation du nombre d'attributs. En effet, ce phénomène s'explique de façon théorique : les FAs n'utilisant qu'un sous-ensemble d'attributs pour construire chaque arbre de décision, ne souffrent pas de l'augmentation du nombre d'attributs, alors que les SVMs sont directement impactés par l'augmentation de la dimension de leur espace de travail.

Ainsi, nous avons décidé de privilégier les FAs dans la suite de nos travaux. Cependant, nous sommes conscients que d'autres implémentations et d'autres variantes des SVMs existent et pourraient sûrement rivaliser avec les FAs.

#### 7.1.4 Choix de la méthode de fusion

Comme nous avons pu le voir dans la sous-section 5.3.2, un grand nombre de méthodes de fusion existent dans la littérature. Nous avons choisi parmi celles-ci des méthodes par moyennes pondérées pour leur simplicité d'implémentation, leur rapidité de calcul et les bons résultats qu'elles fournissent. Ainsi, la moyenne et l'opérateur AWFO (*cf.* sous-section 5.3.2) sont comparés à un troisième opérateur de fusion que l'on a nommé Recall Weighted Fusion (RWF). L'opérateur RWF pondère chaque classification (une par objet) d'une même classe par le rappel de la classification sur l'ensemble de la classe :

$$\mathcal{P}_{RWF}^C = \sum_{O \in C} w_O \mathcal{P}_O, \quad (7.1)$$

avec :

$$\forall O \in C, r_O = \text{Rappel}(l_O, BD), \quad \text{et} \quad w_O = \frac{r_O}{\sum_{o_i \in C} r_{o_i}}, \quad (7.2)$$

où  $l_O$  est la classification obtenue pour l'objet  $O$ .

Afin de comparer les différentes méthodes de fusion, nous avons déroulé la chaîne de traitements  $\mathbb{PPN}$  sur le jeu de données décrit dans la sous-section 7.2.1 jusqu'à l'étape d'inspection par objet. Puis, nous avons appliqué les trois méthodes de fusion décrites précédemment. Enfin, nous avons comparé les résultats des classifications. L'ensemble des résultats chiffrés sont montrés dans le Tableau 7.3. Sur notre jeu de données, les trois méthodes donnent des résultats




FIGURE 7.3 – Comparaison des résultats de classifications par FA et par SVM suivant le nombre d'attributs utilisés : en fonction de la précision globale (en haut) et du temps (en bas).

similaires : une précision globale de 89 % et un indice Kappa de 88 %. Cependant, on peut noter que la méthode de fusion par RWF permet d'augmenter le rappel des classifications, en maintenant les valeurs de précision par classe. C'est le cas en particulier sur la classe *bâti* où le rappel passe de 55 % (pour AWFO et la moyenne) à 75 % pour la méthode RWF. Sur les autres classes, il est toujours entre 80 et 90 %. Les précisions par classe sont elles aussi entre 80 et 90 % sur les différentes classes de la BD. Ainsi, la méthode RWF permet d'améliorer très légèrement le Kappa et la précision globale de la classification.




FIGURE 7.4 – Comparaison des résultats de classification avec les trois méthodes de fusion : (a) AWFO, (b) moyenne et (c) RWF) .

### 7.1.5 Premiers pas vers un passage à l'échelle

La méthode MLMOL nécessite de réaliser une classification de toute l'image pour chaque objet de la BD. Ainsi, avec l'augmentation de la surface couverte par la BD et par l'image, le nombre de classifications et la taille de l'image à classifier vont augmenter. Par exemple, sur la zone d'étude proposée dans le chapitre suivant, sur une surface de 32 km<sup>2</sup>, la BD comporte près de 5000 objets (*cf.* Tableau 8.1) et l'image Pléiades contient 128 000 000 pixels. Le temps de calcul va donc vite devenir problématique. Nous proposons donc ici une méthode afin de réduire le nombre d'objets à inspecter, que nous avons utilisée dans la Partie IV. D'autres méthodes permettant, par exemple, de réduire le nombre de pixels à classifier, sont proposées en perspectives (*cf.* sous-section 10.3.2). La méthode proposée consiste à ne prendre en compte que les plus gros objets de chaque classe dans le processus. Ce choix est motivé par le fait que la BD OCS utilisée comporte un grand nombre d'objets de petite taille, non forcément représentatifs de leurs classes d'appartenance. Ainsi, uniquement les N plus gros objets de chaque classe sont inspectés.

<b>Précision</b> (par classe)			
	AWFO	Moyenne	RWF
<i>Forêts non-discriminées</i>	0,91	0,91	0,91
<i>Feuillus</i>	0,83	0,83	0,83
<i>Conifères</i>	0,96	0,96	0,96
<i>Champs de céréales</i>	0,92	0,91	<b>0,93</b>
<i>Formation herbacée</i>	0,87	<b>0,88</b>	0,86
<i>Bâtiments</i>	0,84	<b>0,86</b>	0,82
<i>Conifères mixte</i>	0,79	0,81	<b>0,83</b>
<i>Feuillus mixte</i>	0,90	0,90	0,90
<i>Eau</i>	1	1	1

<b>Rappel</b> (par classe)			
	AWFO	Moyenne	RWF
<i>Forêts non-discriminées</i>	0,85	<b>0,86</b>	0,85
<i>Feuillus</i>	0,90	0,80	0,90
<i>Conifères</i>	0,95	0,95	<b>0,96</b>
<i>Champs de céréales</i>	0,85	<b>0,87</b>	0,84
<i>Formation herbacée</i>	0,92	<b>0,93</b>	0,92
<i>Bâtiments</i>	0,50	0,56	<b>0,75</b>
<i>Conifères mixte</i>	<b>0,89</b>	0,88	<b>0,89</b>
<i>Feuillus mixte</i>	<b>0,88</b>	<b>0,88</b>	0,87
<i>Eau</i>	1	1	1

<b>F-Score</b> (par classe)			
	AWFO	Moyenne	RWF
<i>Forêts non-discriminées</i>	0,88	0,88	0,88
<i>Feuillus</i>	0,86	0,86	0,862
<i>Conifères</i>	0,96	0,96	0,96
<i>Champs de céréales</i>	0,88	<b>0,89</b>	0,88
<i>Formation herbacée</i>	0,90	<b>0,91</b>	0,89
<i>Bâtiments</i>	0,63	0,68	<b>0,78</b>
<i>Conifères mixte</i>	0,84	0,85	<b>0,86</b>
<i>Feuillus mixte</i>	0,89	0,89	0,89
<i>Eau</i>	1	1	1

<b>Kappa</b>			
	AWFO	Moyenne	RWF
	0,879	0,883	<b>0,884</b>

<b>Précision globale</b>			
	AWFO	Moyenne	RWF
	0,894	0,897	<b>0,898</b>

Tableau 7.3 – Comparaison des résultats de classification avec les trois méthodes de fusions de classifications : AWFO, moyenne et RWF.



## 7.2 Expériences sur un jeu de données généré

### 7.2.1 Description du jeu de données

Comme une vérité terrain de très bonne qualité est toujours compliquée à obtenir et reste un problème insolvable dans le domaine de la télédétection, un jeu de données a été généré à partir d'une image satellite THR Pléiades, à une résolution de 0,5 m. Plusieurs morceaux d'images, dont on connaissait *a priori* la classe d'occupation du sol (issue de différentes BD, vérifiée visuellement), ont été regroupés pour former une image de 1 000×1 000 pixels. Chaque morceau est un carré de 100×100 pixels, provenant d'une seule classe, sauf dans le cas de classes contenant des objets plus petits (*e.g.*, bâti). Dans ce cas, les pixels du voisinage sont non-étiquetés. La nomenclature utilisée est composée de 9 classes extraites de différentes BD d'OCS : *eau*, *forêts mixtes de feuillus*, *forêts mixtes de conifères*, *bâtiments*, *formation herbacée*, *champs de céréales*, *forêts de conifères*, *forêts de feuillus* et *forêts non-discriminées*. L'image ainsi générée est montrée sur la Figure 7.5a, les classes correspondantes et la légende sur les figures 7.5b et 7.5c. Les objets d'une même classe sont distribués en diagonale afin qu'un objet ait dans son voisinage des objets de différentes classes. L'étiquetage associé constitue la vérité terrain pour les deux expériences de complétion et de mise à jour de BD décrites ci-après.

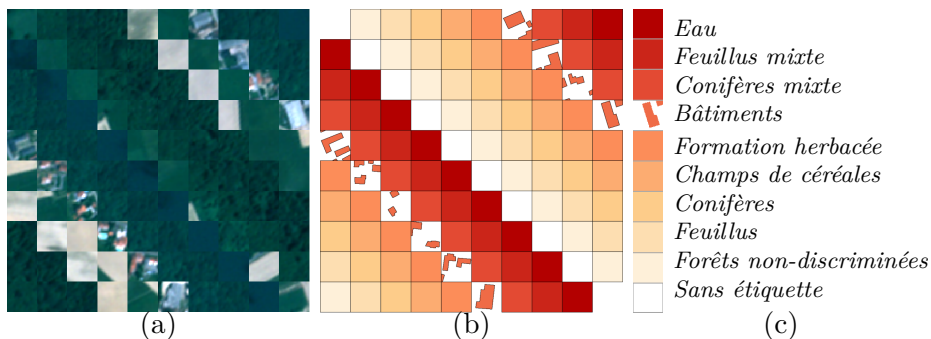


FIGURE 7.5 – Présentation du jeu de données générées : (a) l'image générée à partir d'une image Pléiades (utilisée pour mettre à jour la BD), (b) la vérité terrain et (c) la légende des classes composant la BD. Chaque classe est représentée par une couleur différente et chaque objet  $(i, j)$  fait 100×100 pixels.

### 7.2.2 Attributs et classification

Dans cette série d'expérimentations, différents types d'attributs (décrits dans la sous-section 7.1.1) ont été utilisés. Ces attributs sont répartis ainsi : 13 attributs spectraux (*e.g.*, NDVI, SAVI, *etc.*), 10 attributs de textures (coefficients d'Haralick et entropie des gradients, *cf.* section 3.2.1) et environ 150 attributs morphologiques (les PAs calculés sur différents attributs à différents échelles,

*cf.* sous-section 3.3.2).

Par ailleurs, la méthode LPN nécessite une méthode de classification fournissant une carte de confiance. Dans cette série d'expériences, nous avons choisis les Forêts Aléatoires (FA) dont la marge fournit une mesure robuste de confiance (section 5.2.2).

### 7.2.3 Complétion

Dans un premier temps, l'influence du taux de couverture de la BD initiale (et donc de la surface à compléter) est étudiée. Dans ce but, plusieurs BDs ont été dérivées de la vérité terrain, en supprimant de manière aléatoire un nombre plus ou moins important d'objets. Ainsi, pour chaque pourcentage de couverture (10, 20, ..., 90), dix BDs ont été générées (pour un total de 90 BDs distinctes). Notre méthode est appliquée à chacune des BDs et les résultats des classifications sont comparés à la vérité terrain, afin de calculer les taux de bonnes classifications. Ces derniers sont alors moyennés par pourcentage de couverture. Enfin, pour comparer notre méthode aux méthodes de l'état-de-l'art, le même protocole est appliqué en utilisant une classification classique par FA et par SVM (avec un noyau linéaire). La Figure 7.6 montre les résultats de quelques classifications individuelles et l'ensemble des résultats est rassemblé dans la Figure 7.8 (en haut). Dans cette expérimentation, notre méthode obtient de meilleurs taux de bonne classification que les deux méthodes de l'état-de-l'art, dès que le pourcentage de couverture de la BD initiale est supérieur à 40%. En dessous de cette valeur, les trois méthodes ont des résultats comparables. Ainsi, la multiplication des classifications introduite dans notre méthode permet d'obtenir des résultats plus robustes.




FIGURE 7.6 – Résultats de la classification pour différentes couvertures de la BD initiale, de gauche à droite 40 %, 60 % et 90 % de couverture.

### 7.2.4 Mise à jour

Par ailleurs, l'influence du pourcentage de changement sur notre méthode a été étudiée. Pour cela, 6 bases de données ont été dérivées de la vérité terrain en translatant chaque objet de la BD d'un nombre croissant de pixels. Comme pour

l'expérimentation précédente, les taux de bonne classification sont calculés et comparés à ceux obtenus par FA et par SVM (Figure 7.8 en bas). Les résultats des classifications pour quelques valeurs de changements sont montrés sur la Figure 7.7. Ici, les FAs donnent de meilleurs résultats quand le pourcentage de changement est faible ( $< 25\%$ ), alors que les FAs sont plus performantes quand ce taux de changements dépasse les 30%. Notre méthode reste toujours entre les deux méthodes précédentes, ce qui confirme la stabilité de celle-ci. De plus, on peut remarquer que le taux de bonne classification décroît excessivement avec de forts taux de changements (moins de 50% de bonne classification pour 30% de changements). Cependant, ces taux de changements (répartis sur l'ensemble des classes de la BD) ne sont pas très représentatifs de la réalité.



FIGURE 7.7 – Résultats de la classification pour différents pourcentages de changement entre BD initiale et l'image, de gauche à droite 40 %, 20 % et 10 % de changements.

### 7.2.5 Complétion et mise à jour conjointes

Dans un troisième temps, les capacités de la méthode  $\mathbb{L}\mathbb{P}\mathbb{N}$  en terme de complétion et de mise à jour de BDs ont été validées conjointement. Pour ce faire, plusieurs BDs ont été générées en faisant varier deux paramètres : le pourcentage de couverture de la BD initiale (de 10 à 100%) et le pourcentage de changement entre la BD et l'image (de 0 à 80 %). Les résultats sont présentés sur la Figure 7.9. La surface 3D résultante permet de confirmer la stabilité de notre méthode autant en terme de couverture qu'en terme de changements. En effet, dans la zone correspondant à ce qui existe dans le cas d'une vraie BD d'OCS, *i.e.*, à de faibles valeur de changements ( $< 40\%$ ) et avec une couverture de la BD initiale supérieure à 30%, la précision reste supérieure à 0,7.

## 7.3 Conclusion

Dans ce chapitre, nous avons montré comment la méthode d'apprentissage et de classification MLMOL a été intégrée dans une chaîne de traitements complète permettant de s'adapter au mieux à la fois aux images disponibles (extraction




FIGURE 7.8 – Évolution des taux de bonne classification en fonction (**en haut**) de la couverture de la BD initiale et (**en bas**) du pourcentage de changement introduit dans la BD, pour les FAs, les SVMs multi-classes (MC) et la méthode LFN.




FIGURE 7.9 – Évolution de la précision de notre méthode en fonction de la couverture de la BD initiale et du pourcentage de changements introduit dans cette BD.

d'attributs) et aux thèmes de la BD à mettre à jour (sélection d'attributs, choix du classifieur). De plus, nous avons adapté chaque étape de la chaîne de traitements à partir d'un jeu de données généré. Puis, nous avons validé globalement la capacité de notre chaîne de traitements en terme de complétion et de mise à jour de BD sur ce même jeu de données.

Nous verrons dans le chapitre suivant, que la chaîne de traitements  $\mathbb{L}\mathbb{P}\mathbb{N}$  construite dans ce chapitre peut être appliquée sur un jeu de données réelles, composé d'une image satellite Pléiades et de la BD-OCS-GE de l'IGN.

## Quatrième partie

# Application de la méthode LUPIN à la mise à jour de données d'Occupation du Sol



# Mise à jour de BD OCS à partir d'une image Pléiades

---



## Sommaire

---

<b>9.1</b>	<b>Différentes résolutions spatiales . . . . .</b>	<b>138</b>
9.1.1	Présentation des données . . . . .	138
9.1.2	Résultats . . . . .	140
9.1.3	Étude visuelle . . . . .	141
<b>9.2</b>	<b>Données multi-temporelles . . . . .</b>	<b>143</b>
9.2.1	Présentation des données . . . . .	143
9.2.2	Méthodes utilisées . . . . .	143
9.2.3	Résultats . . . . .	148
9.2.4	Analyse visuelle . . . . .	148
<b>9.3</b>	<b>Conclusion . . . . .</b>	<b>150</b>

---



Nous avons vu dans les deux chapitres précédents, la mise en place d'une chaîne de traitements pour la mise à jour de BD-OCS. Nous ne voulons pas terminer notre travail sans appliquer cette méthode sur des données réelles. Nous montrons dans ce chapitre aussi bien la robustesse de l'approche que sa généralité, grâce à différentes expériences sur un jeu de données réelles. Ce jeu de données, composé d'une image satellite THR Pléiades et d'une BD-OCS, est décrit dans la section 8.1. Une première série de résultats sur une BD simplifiée sémantiquement est proposée dans la section 8.2. Puis, la chaîne de traitements est appliquée sur la BD OCS-GE de l'IGN (*cf.* section 8.3), afin de répondre à la problématique présentée dans la section 1.3. Enfin, nous montrerons dans la dernière section (8.3.3) que notre méthode peut également fournir une aide importante pour la création et la complétion de la BD-OCS initiale, ainsi que l'extension d'une BD-OCS sur une zone géographique plus grande.

## 8.1 Jeu de données

### 8.1.1 Image satellite

La première composante de notre jeu de données est une image satellite THR Pléiades (*cf.* sous-section 1.2.2), acquise en septembre 2013 (Figure 8.1). L'image acquise couvre une surface de 760 km<sup>2</sup> dans la région de Tarbes (Sud-Ouest de la France), avec une résolution panchromatique ré-échantillonnée à 0,7 m et à 2,80 m en couleur (rouge, vert, bleu et proche-infrarouge). Le produit image utilisé, issu de cette image, a une résolution de 0,5 m en panchromatique et 2 m en couleur.

### 8.1.2 Occupation du sol

La seconde composante de ce jeu de données est base de données (BD)-OCS à mettre à jour. Pour nos besoins expérimentaux deux BD ont été utilisées et sont détaillées ici : la BD-occupation du sol à grande échelle (OCS-GE) produite par l'IGN et une BD-OCS simplifiée.

#### Occupation du sol à grande échelle

La première BD utilisée est la BD-OCS-GE produite par l'IGN (Figure 8.2). Une description détaillée de cette BD a été faite dans la section 1.1. Nous nous intéresserons ici, en particulier, à la composante de couverture du sol dont la nomenclature hiérarchique, composée de quatre niveaux, est compatible avec Corine Land Cover (CLC) et avec divers BD-OCS régionales existantes. Le niveau le plus détaillé contient 15 classes qui sont précisées dans le Tableau A.2.

La zone d'étude se situe au Sud-Est de Tarbes, elle couvre les communes de Tarbes Aureilhan et Salles-Adour (Figures 8.1 et 8.2), sur une surface de 32 km<sup>2</sup> (4 km × 8 km). Les trois BDs-OCS-GE couvrant ces communes ont été fusion-



FIGURE 8.1 – Image Pléiades ©CNES (2013), distribution Airbus DS / Spot image, acquise en septembre 2013 sur la zone d'étude de Tarbes, en vert : la zone d'étude utilisée dans ce chapitre (4 km × 8 km).

Classe	Nombre d'objets	Surface moyenne	Surface totale	% de couverture
<i>Zones bâties</i>	1447	2 189 m <sup>2</sup>	3 168 715 m <sup>2</sup>	10,32 %
<i>Zones non bâties</i>	1643	1 145 m <sup>2</sup>	1 882 622 m <sup>2</sup>	6,13 %
<i>Zones à matériaux minéraux</i>	177	2 547 m <sup>2</sup>	450 971 m <sup>2</sup>	1,46 %
<i>Surfaces d'eau</i>	22	13 994 m <sup>2</sup>	307 880 m <sup>2</sup>	1 %
<i>Peuplement de feuillus</i>	309	36 168 m <sup>2</sup>	11 176 209 m <sup>2</sup>	36,40 %
<i>Peuplement mixte</i>	3	12 543 m <sup>2</sup>	37 630 m <sup>2</sup>	0,12 %
<i>Autres formations arborées</i>	82	2 180 m <sup>2</sup>	178 789 m <sup>2</sup>	0,58 %
<i>Formations arbustives</i>	24	8 506 m <sup>2</sup>	204 156 m <sup>2</sup>	0,66 %
<i>Autres formations ligneuses</i>	4	6 917 m <sup>2</sup>	27 669 m <sup>2</sup>	0,09 %
<i>Formations herbacées</i>	944	14 056 m <sup>2</sup>	13 268 978 m <sup>2</sup>	43,21 %
<b>Total</b>	4913	6 772 m <sup>2</sup>	30 703 619 m <sup>2</sup>	100 %

Tableau 8.1 – Détails des objets de chaque classe de la BD, présents sur la zone d'étude de Tarbes.

<i>Zones bâties</i>	
<i>Zones non bâties</i>	
<i>Zones à matériaux minéraux</i>	
<i>Surfaces d'eau</i>	
<i>Peuplement de feuillus</i>	
<i>Peuplement mixte</i>	
<i>Autres formations arborées</i>	
<i>Formations arbustives</i>	
<i>Autres formations ligneuses</i>	
<i>Formations herbacées</i>	

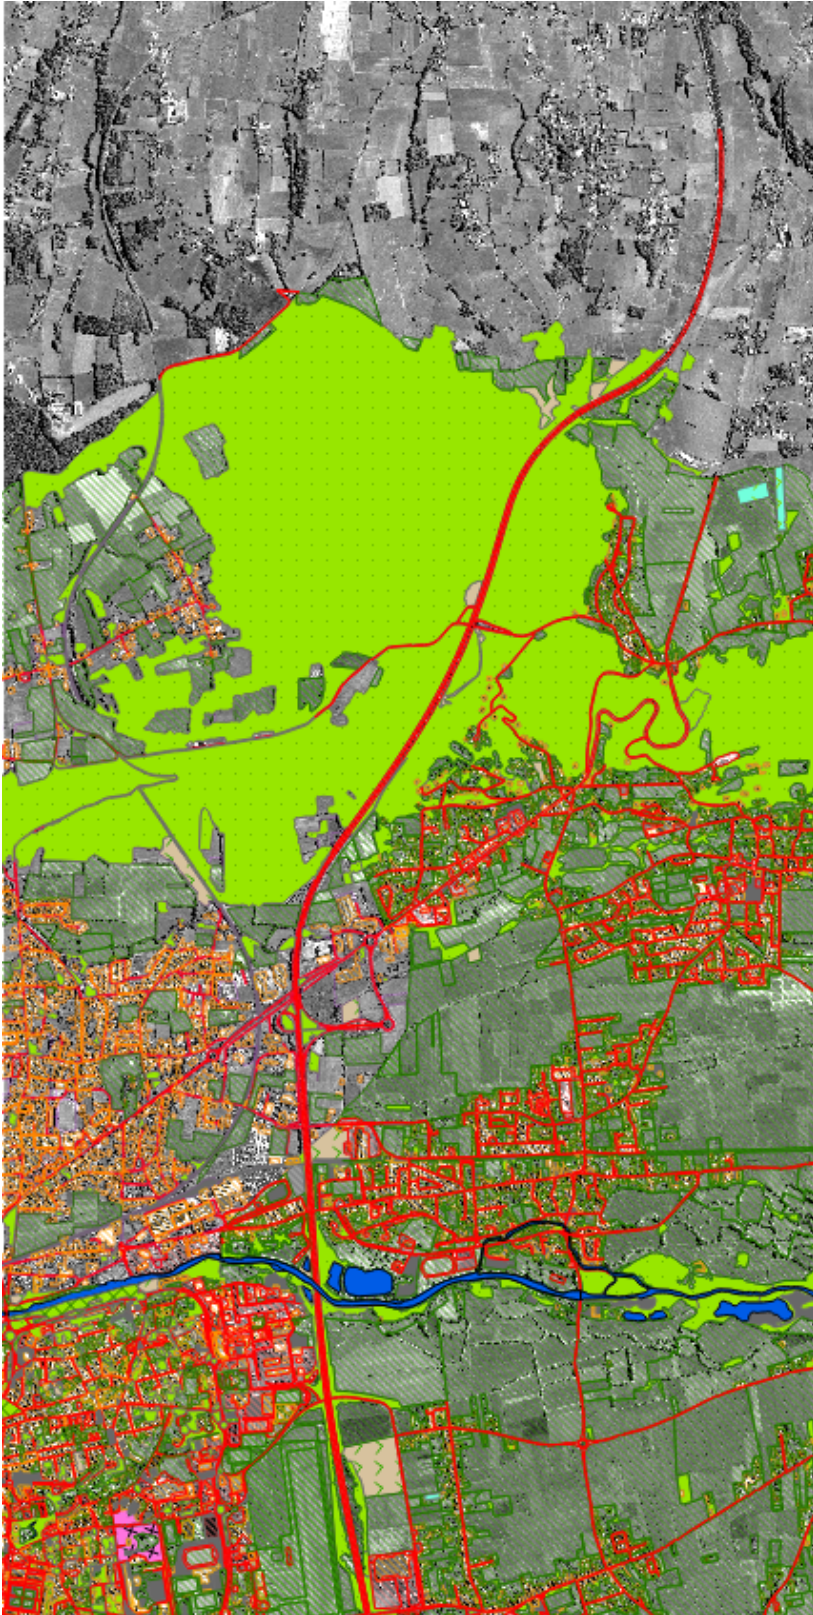
Tableau 8.2 – Légende des classes d'OCS présentes sur la zone d'étude de Tarbes et extraite de la nomenclature OCS-GE (cf. Tableau A.2).

nées sur cette zone. La BD ainsi constituée possède 4913 objets de 10 classes : *zones bâties*, *zones non bâties*, *zones à matériaux minéraux*, *surfaces d'eau*, *peuplement de feuillus*, *peuplement mixte*, *autres formations arborées*, *formations arbustives*, *autres formations ligneuses* et *formations herbacées* (cf. Tableau 8.2). Cinq classes ne sont pas représentées sur la zone (e.g., *Neige et glace*, *Peuplement de conifères*, ...). De plus, quatre classes sont prédominantes sur la zone, et représentent à elles seules, 96 % de la surface couverte par la BD, il s'agit des classes : *zones bâties*, *zones non bâties*, *peuplement de feuillus*, *formations herbacées* (cf. Tableau 8.1). On peut également remarquer que la BD comporte un certain nombre de « trous », sur lesquels, on ne dispose d'aucune information. De plus, la zone d'étude comporte également une grande partie hors de la couverture de la BD à l'est (Figure 8.2).

### Occupation du sol simplifiée

Enfin, nous avons généré une BD simplifiée sémantiquement, sur une zone d'une surface de 16 km<sup>2</sup> (4 km × 4 km). Cette BD d'OCS simplifiée est obtenue





2 km

FIGURE 8.2 – BD OCS-GE produite par l'IGN (*cf.* légende associée dans le Tableau 8.2), la partie *est* correspond à une zone non couverte par la BD.

en fusionnant les classes de différentes BDs pour atteindre un niveau de détail sémantique comparable à CLC, avec la résolution de la BD-OCS-GE (Figure 8.3b). Ainsi, nous avons fait une telle démarche pour la BD-Forêt (15 classes regroupées en une) et le RPG (23 classes). La fusion de classes d'apparences multiples (*e.g.*, feuillus, résineux) cherche aussi à évaluer si la méthode mise au point est bien capable de gérer des classes d'apparences multiples. On appellera ces deux classes : *Forêts* et *Champs*. On peut noter que la BD a une nomenclature incomplète, ainsi des thèmes comme les *routes* ou les *bâtiments* ne sont pas présents dans la BD. Par ailleurs, différents types de changements existent entre la BD et l'image, outre les changements *forêts* vers *champs* et *champs* vers *forêts*, on peut signaler que la BD ne contient pas l'ensemble des *champs* et des *forêts*. Ainsi, les zones non couvertes de la BD (en blanc sur la Figure 8.3b) contiennent des *champs*, des *forêts*, des *routes* et des *bâtiments*.

## 8.2 Résultats sur OCS simplifiée

La chaîne de traitements  $\mathbb{L}\mathbb{P}\mathbb{N}$  est d'abord appliquée au jeu de données OCS simplifiée (*cf.* section 8.1.2). Les résultats obtenus sont présentés dans la Figure 8.3. Dans ce calcul, les classifications utilisent une trentaine d'attributs dérivés des canaux de l'image Pléiades (12 attributs spectraux et une vingtaine d'attributs de texture). Seule cette sélection manuelle des attributs est réalisée (il n'y a pas de sélection automatique par classe). Les classifications ont été réalisées par FAs. On peut remarquer que toutes les zones non étiquetées par la BD initiale ont été classifiées en *forêts* ou *champs* par notre méthode (Figure 8.3c), mais la confiance associée est faible sur les zones de type *bâti* ou *routes* (qui ne sont pas présents dans la BD).

Sur la carte de changements (Figure 8.3d), les zones rouges étendues correspondent soit à des zones de changements (croissance ou diminution de la forêt) soit à des zones non-étiquetées dans la BD initiale (nouveaux champs). Les zones blanches correspondent aux zones d'incertitude, qui sont principalement les objets non présents dans la BD, comme les *routes* et les *bâtiments*. Ces incertitudes pourraient être réduites facilement en introduisant plus de classes dans la BD initiale.

De plus, une étude par classe peut être réalisée. En effet, la Figure 8.3e montre la différence entre la classe *forêts* initiale et le résultat de la classification. Les apparitions sont affichées en bleu et les disparitions en rouge. Le résultat analogue obtenu sur la classe *champs* est illustré sur la Figure 8.3f. Ces deux images montrent qu'une détection de changements précise peut être effectuée. Par exemple, les haies et les bosquets, qui ne sont pas présents dans la classe *forêts* de la BD initiale, sont correctement identifiés sur l'image. Dans la classe *champs*, la plupart des bords de champs sont correctement marqués comme disparus. Ces disparitions sont dues à la délimitation approximative des champs réalisée par photo-interprétation sur une image à plus faible résolution.

Ces premiers résultats permettent de confirmer l'intérêt de la méthode, ce-

pendant, l'absence de vérité terrain empêche le calcul d'indicateurs chiffrés de qualité de la classification, comme le taux de bonne classification.

### 8.3 Résultats sur OCS-GE

Dans un deuxième temps, les données OCS-GE décrite dans la section 8.1.2. Comme indiqué dans le chapitre précédent, nous avons sélectionné les 10 objets de chaque classe ayant les plus grandes surfaces afin de réduire les temps de calculs (*cf.* sous-section 7.1.5). Cette sélection d'objets constitue notre ensemble d'apprentissage pour la sélection d'attributs et pour les différentes classifications. La BD complète est utilisée pour produire la carte de changements et pour calculer les matrices de confusion.

Pour valider les expérimentations faites dans le chapitre précédent sur le jeu de données réel, plusieurs scénarii sont proposés, en faisant varier différentes étapes de la méthode. Le choix des attributs de classifications est réalisé :

- de manière manuelle et identique pour chacune des classes de la BD, (*sélection manuelle*),
- pour chaque classe de manière globale (*sélection globale*),
- par famille d'attributs (*sélection par famille*).

Pour la méthode *manuelle*, 59 attributs sont utilisés. Il s'agit de l'ensemble des attributs spectraux, des profils morphologiques, de l'entropie des gradients et des SFS. Nous n'avons pas ici utilisé l'ensemble des attributs disponibles, mais uniquement sélectionné les familles d'attributs qui nous semblaient les plus pertinentes aux vus des résultats obtenus dans le chapitre précédent (*cf.* sous-section 7.1.2). Les deux méthodes de sélection d'attributs utilisent ces mêmes attributs, ainsi que 84 attributs de texture (type Haralick) calculés à différentes échelles sur le canal panchromatique. Seuls les attributs issus de la librairie colorDescriptor (CD) et les attributs de texture Haralick sur les autres canaux (RVB-IR) ne sont pas utilisés ici, car les temps de calcul et le stockage de ces attributs sur une image de taille importante était rédhibitoire. La sélection globale ne garde que les 20 meilleurs attributs de chaque classe en utilisant l'importance des attributs issue des FAs (*cf.* chapitre 5). La sélection par familles d'attributs effectue une première sélection des 10 meilleurs attributs de chaque famille (SP : spectral, HK : texture Haralick et AP : morphologique), puis une sélection des 20 meilleurs attributs. Compte tenu des conclusions tirées dans le chapitre précédent sur la comparaison des classifieurs (*cf.* sous-section 7.1.3), les classifications dans les différents scénarii sont réalisées par FA.

Enfin, trois méthodes de fusion des classifications par classes, présentées dans la sous-section 7.1.4, sont comparées :

- par moyenne des probabilités par classification (*moyenne*),
- par moyenne pondérée sur le rappel de chaque classification sur la classe en cours (RWF),
- par AWFO.

Les résultats des différents scénarii sont d'abord évalués de manière chiffrée,



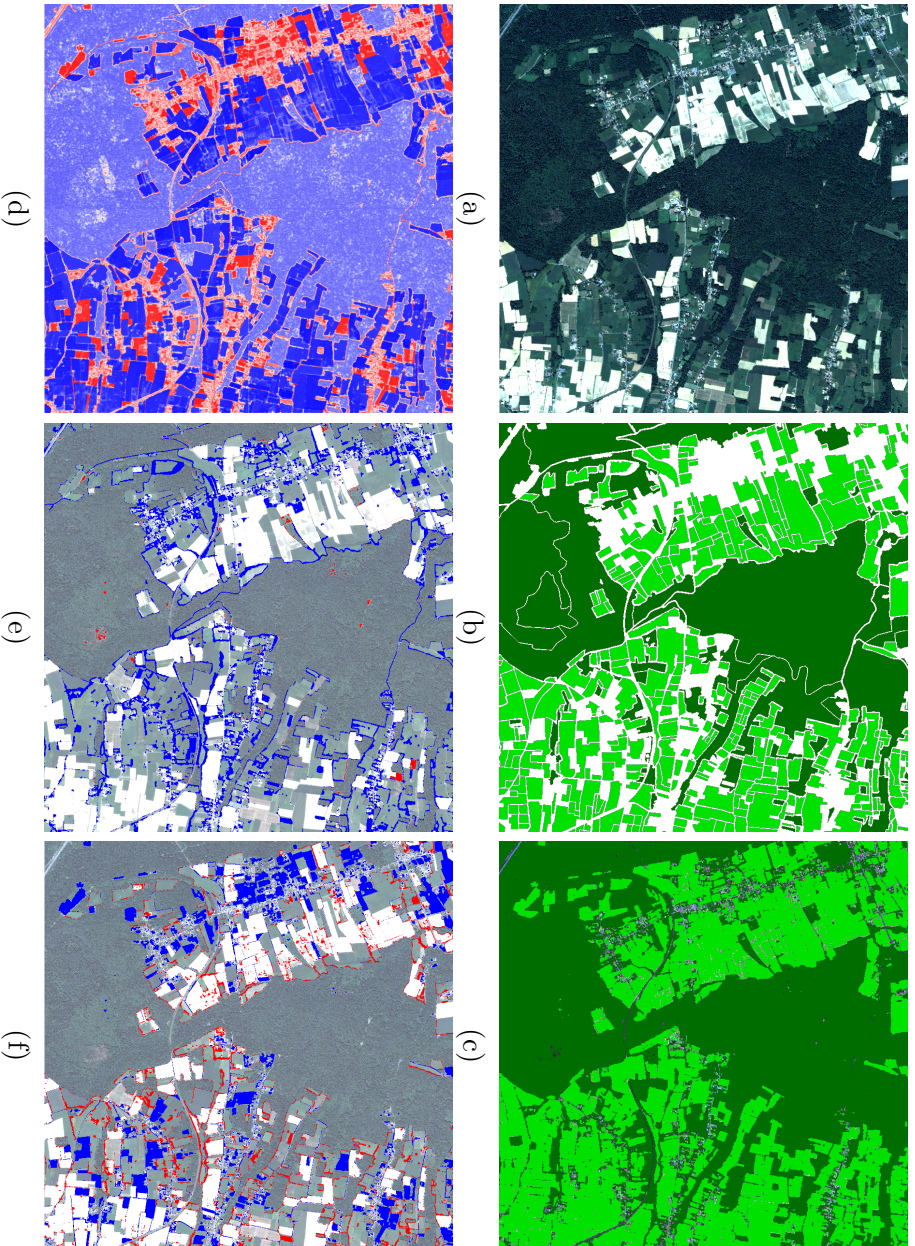


FIGURE 8.3 – Résultats sur la BD simplifiée : (a) l'image, (b) la BD composée de deux classes (*champs* en vert clair, *forêts* en vert foncé et les zones non couvertes en blanc), (c) la classification (avec les mêmes couleurs), (d) la carte de probabilité de changement (bleu : pas de changement, rouge : changement et blanc : zone de confusion), et les différences (avant/après) pour : (e) la classe *forêts* et (f) la classe *champs* (bleu : apparition et rouge : disparition).

Sélection	<i>Manuelle</i>			<i>Sélection globale</i>			<i>Sélection par famille</i>		
Fusion	A	M	R	A	M	R	A	M	R
Précision	<b>0,67</b>	<b>0,67</b>	0,66	0,63	0,65	0,66	0,61	0,66	0,65

Tableau 8.3 – Comparaison des taux de bonne classification (précision) pour les différents scénarii (A : AWFO, M : moyenne et R : RWF).

puis le meilleur scénario est étudié visuellement en détail (classification classe par classe, classification finale et carte de changements).

### 8.3.1 Étude chiffrée des classifications

Une mesure de la précision d’une classification est donnée par le taux de bonne classification (*cf.* section 5.4). Cette mesure correspond au nombre de pixels correctement classés, divisé par le nombre total de pixels. Les taux de bonne classification des neuf scénarii proposés sont disponibles dans le Tableau 8.3. Avec des taux de bonne classification compris entre 63 et 67 %, aucun scénario ne semble se démarquer autant vers le haut que vers le bas. Dans le cas de la sélection manuelle des attributs, la méthode de fusion n’apporte aucune différence significative. Alors que pour les sélections d’attributs globale et par famille d’attributs, les fusions par moyenne et par RWF améliorent un peu le taux de bonnes classifications, par rapport à la fusion par AWFO.

Deux mesures sont utilisées ici afin de comparer de manière plus détaillée les classifications de chaque classe : la précision utilisateur (ou exactitude) et la précision producteur (ou rappel) (*cf.* section 5.4). La précision utilisateur est définie comme le nombre de pixels bien classés dans une classe divisée par le nombre de pixels classés dans cette classe. La précision producteur est définie comme le nombre de pixels bien classés dans une classe divisée par le nombre de pixels de cette classe dans la vérité terrain.

L’utilisation de l’ensemble des attributs (*manuelle*) améliore légèrement la précision producteur, alors que la sélection globale des attributs améliore la précision utilisateur. De plus les méthodes de fusion par AWFO et par moyenne améliorent légèrement la précision producteur, alors que la fusion par RWF tire vers le haut les faibles valeurs de production utilisateur. De manière générale, on peut différencier clairement deux comportements différents sur les classes très représentées (*zones bâties, routes, peuplement de feuillus et formations herbacées*) et sur les classes sous représentées (*zones à matériaux minéraux, peuplement mixte, ...*). Pour ces premières, les précisions utilisateurs sont toujours très bonnes voir excellentes (jusqu’à 97 %), alors que le deuxième groupe obtient des résultats très décevants (inférieur à 10 %). La présence de ces classes sous-représentées dégrade grandement les précisions producteurs des autres classes, car elles sont sur-représentées dans la classification finale et elles introduisent de la confusion entre les classes. Les classes *peuplement de feuillus* et *formations*



*herbacées* obtiennent dans tous les cas, les meilleures précisions (utilisateur et producteur), avec des valeurs toujours au-dessus des 70 % et atteignant les 97 %. De plus, l'étude des 4 classes majoritaires (*zones bâties*, *routes*, *peuplement de feuillus* et *formations herbacées*) qui représente plus de 95 % de la couverture de la BD (cf. Tableau 8.1), montre les bonnes performances de la méthode (classes marquées par (\*) dans le Tableau 8.4). En effet, si on ne considère que ces classes, le taux de bonne classification est de 78,5 %, dans le cas de la *sélection globale* et de la fusion par RWF. En particulier, les méthodes utilisant la sélection d'attributs automatique surpassent toujours la méthode sans cette étape de sélection d'attributs.

On peut conclure tout d'abord que la comparaison des qualités des classifications ne permet pas de faire ressortir une méthode parmi les autres. De manière générale, les très bons résultats pour les classes *formations herbacées* et *peuplement de feuillus* et les résultats corrects des classes *zones bâties*, *zones non bâties* et *surfaces d'eau* semblent prometteur pour la suite. Cependant, les classes peu représentées comme *zones à matériaux minéraux*, *peuplement de conifères* ou *formations arbustives*, obtiennent des résultats très insatisfaisants et dégradent ainsi les taux de bonnes classifications. Ainsi, un travail tout particulier devra être réalisé sur la classification des classes peu représentées (6 classes qui couvrent moins de 5 % de la zone) et une méthode de fusion prenant en compte ces éléments devra être introduite (cf. section 10.3).

### 8.3.2 Étude visuelle

Il s'agit ici d'étudier (1) les classifications classe par classe (avant fusion sur l'ensemble de la BD), (2) la classification finale et (3) la carte de changements obtenue. Bien que l'étude chiffrée n'ait pas pu départager un scénario parmi les autres, l'étude comparative visuelle des cartes de changements issues des différents scénarii permet de mettre en évidence l'avantage des méthodes de sélection automatique. En effet, pour ces dernières, les zones de faibles confiances sont réduites et les fortes valeurs de confiances sont accentuées. Ceci est dû à la meilleure qualité des classifications classe par classe des méthodes utilisant la sélection automatique, ce qui ne ressort pas forcément après fusion au niveau de la BD (sauf dans le cas où l'on n'a étudié que 4 classes dans la partie précédente). Ainsi, dans cette partie, nous allons étudier en détail les résultats du scénario *sélection globale* avec une fusion par RWF.

Dans un premier temps, la classification de chaque classe (issue de la fusion des classifications de chaque objet de la classe) est étudiée sur quatre zones d'intérêt. Deux zones sont situées en milieu rural et sont composées majoritairement de champs (Figure 8.4) et de forêt (Figure 8.5). Les deux autres zones sont situées dans un milieu urbain dense et dans une zone industrielle (Figure 8.6).

La première zone est composée de champs à l'ouest, d'une rivière traversant l'image sur un axe nord-sud, d'une zone pavillonnaire éparse au sud-est et d'une route à l'est (Figure 8.4a). Les différentes fusions de classifications pour

Méthodes	Sélection manuelle			Sélection globale			Sélection par famille		
	AWFO	Mean	RWF	AWFO	Mean	RWF	AWFO	Mean	RWF
<b>Précisions Utilisateur (Exactitude)</b>									
Zones bâties (*)	0,52	0,51	0,48	0,56	0,53	0,51	0,58	<b>0,59</b>	0,58
Zones non bâties (*)	0,59	0,59	0,58	0,64	<b>0,65</b>	0,65	0,54	0,56	0,57
Zones à matériaux minéraux	0,17	<b>0,19</b>	NC	0,17	0,18	<b>0,19</b>	0,12	0,12	0,12
Surfaces d'eau	0,64	0,73	<b>0,81</b>	0,26	0,36	0,35	0,2	0,3	0,32
Peuplement de feuillus (*)	0,94	0,94	0,94	0,93	<b>0,95</b>	0,94	0,94	<b>0,95</b>	<b>0,95</b>
Peuplement mixte	0,01	0,01	0,01	0,01	0,01	0,01	0,01	0,01	0,01
Autres formations arborées	0,07	0,03	NC	0,05	0,01	0,01	0,05	0,03	<b>0,11</b>
Formations arbustives	0,06	0,09	0,12	0,06	0,12	0,16	0,05	0,1	<b>0,15</b>
Autres formations ligneuses	<b>0,09</b>	0,07	0,04	0,05	0,05	0,05	0,05	0,04	0,03
Formations herbacées (*)	0,97	0,97	0,97	0,97	0,96	0,96	<b>0,98</b>	<b>0,98</b>	<b>0,98</b>
Moyenne	0,4	0,41	<b>0,49</b>	0,37	0,38	0,38	0,35	0,37	0,38
Moyenne (*)	0,76	0,75	0,74	<b>0,78</b>	0,77	0,77	0,76	0,77	0,77
Moyenne Pondérée	0,86	0,86	0,86	0,86	0,86	0,86	0,86	<b>0,87</b>	<b>0,87</b>
<b>Précisions Producteur (Rappel)</b>									
Zones bâties (*)	0,41	0,33	0,33	0,33	0,21	0,21	<b>0,49</b>	0,42	0,41
Zones non bâties (*)	<b>0,51</b>	0,5	0,49	0,4	0,39	0,4	0,22	0,21	0,21
Zones à matériaux minéraux	0,07	0,07	NC	0,22	0,2	0,16	<b>0,36</b>	0,35	0,31
Surfaces d'eau	0,39	0,39	0,3	<b>0,47</b>	0,45	0,46	0,45	0,4	0,39
Peuplement de feuillus (*)	0,8	0,84	0,85	0,71	<b>0,86</b>	<b>0,86</b>	0,67	0,85	<b>0,86</b>
Peuplement mixte	0,73	<b>0,83</b>	<b>0,83</b>	0,53	0,8	0,81	0,51	0,79	0,81
Autres formations arborées	0,02	0	NC	<b>0,05</b>	0	0	0,02	0	0
Formations arbustives	0,4	0,35	0,18	0,54	0,5	0,39	<b>0,59</b>	0,53	0,35
Autres formations ligneuses	0,45	0,51	0,64	0,56	0,61	0,7	0,63	0,69	<b>0,87</b>
Formations herbacées (*)	<b>0,72</b>	<b>0,72</b>	0,71	<b>0,72</b>	<b>0,72</b>	<b>0,72</b>	0,7	0,7	0,69
Moyenne	0,45	0,45	<b>0,54</b>	0,45	0,47	0,47	0,46	0,49	0,49
Moyenne (*)	<b>0,61</b>	0,6	0,6	0,54	0,55	0,55	0,52	0,55	0,54
Moyenne Pondérée	0,68	<b>0,69</b>	<b>0,69</b>	0,64	0,68	0,68	0,63	0,68	0,68

Tableau 8.4 – Tableau comparatif des différents scénarii étudiés : exactitude et rappel pour chaque classe et chaque scénario ; la moyenne, la moyenne des quatre classes les plus représentées et la moyenne pondérée par la surface de chaque classe permet de juger les différents scénarii.

les thèmes *zones bâties*, *routes*, *matériaux minéraux*, *eau*, *feuillus*, *champs* et *peuplement mixte* sont représentés sur les images 8.4b-h. La zone bâtie ressort bien sur la Figure 8.4b : la classification ne permet pas d'isoler les bâtiments de manière individuelle, mais elle permet d'identifier clairement les quartiers résidentiels. On peut noter également un peu de confusion avec les zones ombragées et les routes. Sur la Figure 8.4c, la classification des routes est très bonne, en effet, les routes ressortent clairement et précisément, il y a toutefois un peu de confusion avec la classe *eau*. De la même manière, les thèmes *peuplement de feuillus* (f) et *champs* (g) sont très bien classés. Cependant, mise à part ces quatre thèmes bien classés, les autres posent problème. Par exemple, la classe *matériaux minéraux* est confondue presque intégralement avec la classe *route*. La classe *eau* contient en sortie de classification une grande partie des zones d'ombres et la classe *peuplement mixte* fait ressortir la *végétation arborée* et les *zones résidentielles* (qui sont composées de maisons individuelles entourées de jardin et donc d'arbres).




FIGURE 8.4 – Zone 1 : (a) Ortho-image et les classifications (de blanc : appartenant à la classe, vers noir : hors de la classe) pour les classes : (b) *zones bâties*, (c) *routes*, (d) *matériaux minéraux*, (e) *eau*, (f) *feuillus*, (g) *champs* et (h) *peuplement mixte*.

La seconde zone est composée de forêts à l'ouest, de champs à l'est, de quelques habitations au nord-est et d'une petite route (Figure 8.5a). Les remarques sont les mêmes que pour la zone précédente, les classes *bâti*, *route*, *peuplement de feuillus* et *champs* (Figures 8.5b, c, e et h) sont correctement classées, alors que les classes *peuplement mixte* et *autres formations arborées* sont confondues avec l'ombre et les zones résidentielles éparses.

La troisième zone se situe dans le centre-ville de Tarbes, elle est composée d'habitations resserrées et de routes (Figure 8.6-3a). La classification des




FIGURE 8.5 – Zone 2 : (a) Ortho-image et les classifications (de blanc : appartenant à la classe, vers noir : hors de la classe) pour les classes : (b) *bâti*, (c) *route*, (d) *matériaux minéraux*, (e) *feuillus*, (f) *peuplement mixte*, (g) *autres formations arborées* et (h) *champs*.

routes (Figure 8.6-3b) donne de très bons résultats pour distinguer les routes des bâtiments, seulement quelques grands bâtiments sont classés comme route. Ceci est permis, entre autre, par l'utilisation des attributs SFS. Cependant, la classification du bâti ne permet pas de distinguer les bâtiments des routes, les données d'apprentissage doivent contenir des zones mixtes qui gênent la classification. Enfin, la dernière zone est constituée d'entrepôts, de parking et de routes (Figure 8.6). Sur cette zone, la classification de la classe *bâti* pose également problème. Cependant la classe *route* (qui contient aussi les parkings dans la nomenclature utilisée) est plutôt bien classée, sauf certains grands bâtiments qui sont confondus avec des parkings. Cette confusion, que l'on avait déjà observée dans la zone urbaine, pourrait être facilement supprimée par exemple en utilisant une information de hauteur issue de données stéréoscopiques.

La classification finale est obtenue après fusion des classifications par thème. Le résultat sur l'ensemble de la zone est montré sur la Figure 8.7. Les classes *champs* et *peuplement de feuillus* sont très bien classées. Les *routes* et *zones bâties*, sont correctement classées malgré quelques confusions possibles. Cependant, à cause des confusions que l'on a vues dans l'étude des classifications par classe, les classes sous-représentées comme les *zones à matériaux minéraux* ou les *peuplements mixtes* sont très mal classées. La classification obtenue en ne considérant que les 4 classes les plus représentatives et ayant obtenu les meilleurs résultats de classifications (*zones bâties*, *zones non-bâties*, *forêts* et *champs*; marqué par (\*) dans le Tableau 8.4) et la classe *eau*, est illustrée sur la Figure 8.8. Le fait de ne considérer qu'un nombre réduit de classes permet d'obtenir des résul-




FIGURE 8.6 – Zones 3 (en haut) et 4 (en bas) : (a) Ortho-image et les classifications pour les classes : (b) *bâti*, (c) *route*.

tats de classifications beaucoup plus satisfaisants visuellement, ce qui confirme les résultats chiffrés du paragraphe précédent.

La carte de changements obtenue par comparaison de la classification précédente avec la BD initiale, puis pondérée par la confiance dans la classification est montrée sur la Figure 8.9. D'un point de vue général, la grande zone rouge à l'est correspond à une zone non couverte par la BD initiale et ressort donc comme une zone de changement. Les niveaux de rouge montrent donc la confiance dans la nouvelle classification. Les petites zones rouges au Nord de la zone correspondent également à des zones non couvertes par la BD, mais qui sont correctement classées par notre méthode. Enfin, de grandes zones plus claires apparaissent majoritairement sur les zones urbaines / bâties. Ces zones, où la confiance en la classification est faible, sont dues aux confusions que l'on a pu voir dans l'étude des classifications par classe. En effet, si deux classes (ou plus) ont une forte probabilité sur une même zone, alors la confiance en la classification est faible. Ainsi, sur ces zones, la classification est souvent correcte (par exemple sur les routes), mais comme il y a de la confusion avec d'autres classes, la confiance est faible. Comme nous l'avons fait pour la classification, nous avons dérivé la carte de changements issue de la classification des 4 classes les plus représentatives et la classe *eau* (cf. Figure 8.10). Les résultats obtenus montrent une diminution des zones d'indécisions (de couleur blanche), permettant de mieux se focaliser sur les zones de changements.





FIGURE 8.7 – Résultat de la classification sur la zone de Tarbes-Sud (*cf.* légende associée dans le Tableau 8.2).

Par suite, trois zones de changements sont détaillées ici. La première zone (Figure 8.11, en haut) montre une zone à *matériaux minéraux* (en gris sur la BD) qui a été classée comme *formations herbacées* par notre méthode (comme la zone verte sur la BD). Le changement ressort très bien sur la carte de changement associée. La seconde zone (Figure 8.11, au milieu) montre également une zone à *matériaux minéraux* qui est classée comme *formations herbacées* et qui ressort également sur la carte de changement. Enfin sur la dernière zone de changements (Figure 8.11, en bas), d’une part le champs non classé dans la BD est correctement classé par notre méthode, d’autre part l’extrémité nord de ce champs, qui était classé comme forêt dans la BD a été correctement reclassée en champs.

### 8.3.3 Résultats supplémentaires

Un des problèmes rencontré par les équipes de production, mais qui n’était pas le sujet de ce travail, est l’initialisation (la création) de la BD d’OCS à partir de différentes BD existantes. Comme on a pu le voir dans le section 1.1, cette initialisation est le fruit d’un long processus alternant des phases automatiques de fusions de données géographiques et des phases d’interventions manuelles pour la correction des données. Cependant, à cause des contraintes de temps empêchant l’inspection complète de la BD par un opérateur, la BD ainsi produite peut contenir un certain nombre d’incohérences, comme la superposition de différents objets de natures différentes, des imprécisions au niveau des contours des objets, ou l’existence de zones non couvertes par la BD sur l’emprise de cette dernière.

Ainsi, nous allons voir dans cette section, comment notre méthode permet de :

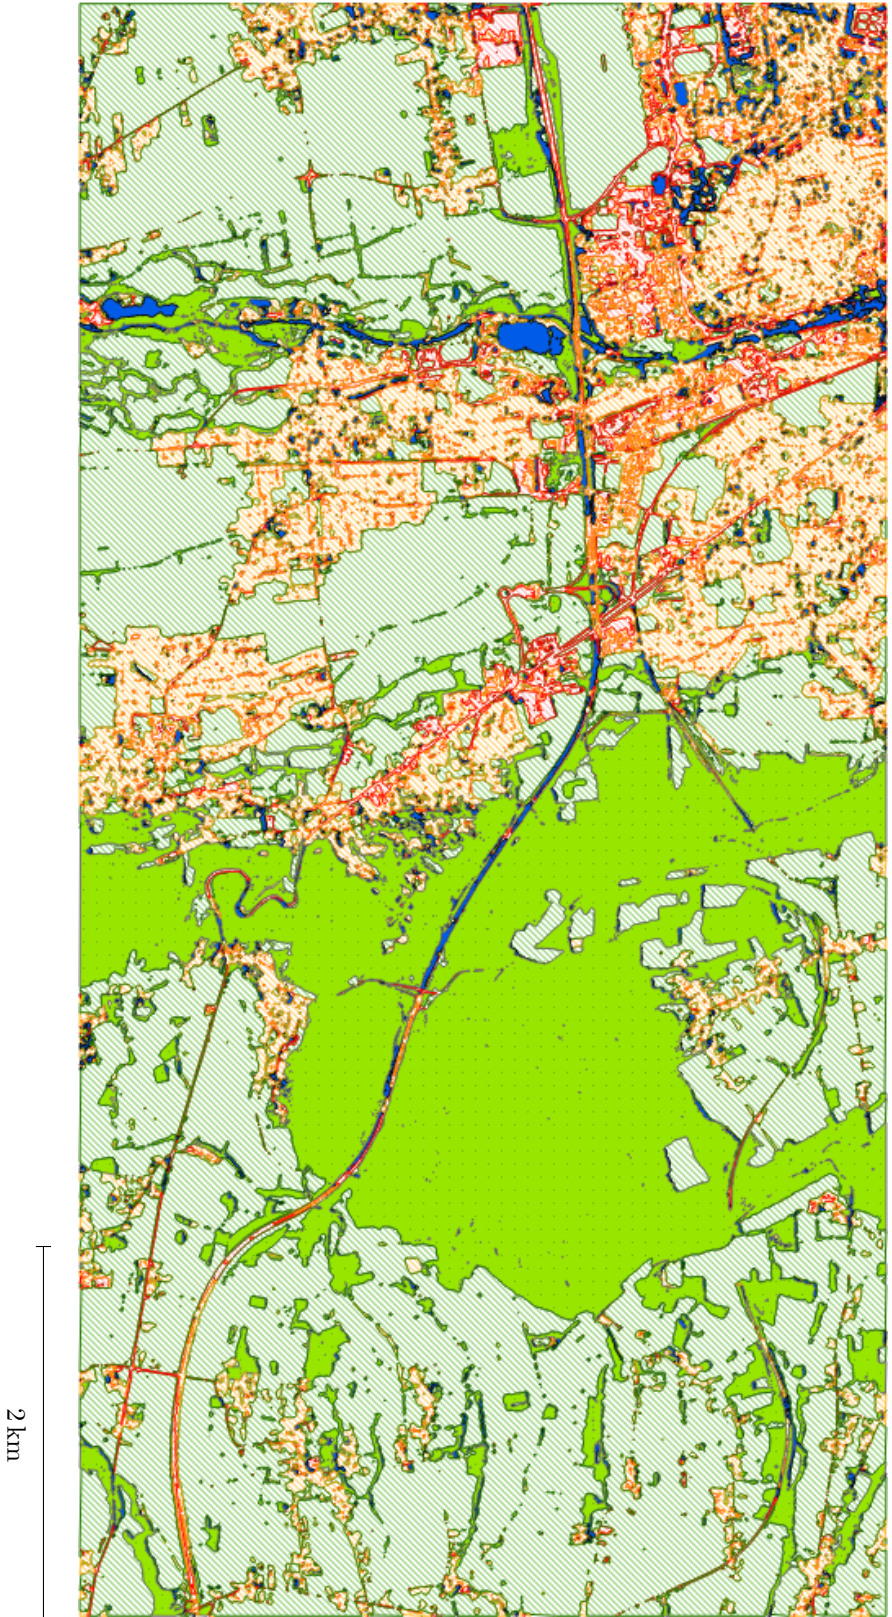


FIGURE 8.8 – Résultat de la classification sur la zone de Tarbes-Sud en ne considérant que les 4 classes les plus représentatives (zones bâties, zones non bâties, forêts et champs) et la classe eau (cf. légende associée dans le Tableau 8.2).






FIGURE 8.9 – Carte de changements (rouge : changement - blanc : confusion - bleu : non changement). Les zones en rouge correspondent à des « trous » dans la base de données initiale.

- prendre une décision lorsque différents objets de différentes classes se superposent ;
- compléter les zones non couvertes en proposant une classification sur ces zones ;
- étendre la couverture d’une BD sur l’ensemble de l’emprise d’une image.

Dans un premier temps, si différents objets voisins issus de différentes BDs sont en désaccord (zone de recouvrement), notre méthode permet de résoudre le problème. En effet, en inspectant chacun des objets individuellement de manière robuste face aux incohérences entre l’image et la BD.

La prise en compte des deux classifications (une par objet concerné) permet de régler cette indécision. Les résultats obtenus sont visibles sur la Figure 8.12. Sur cette figure, on peut voir sur deux zones d’intérêt, à gauche la BD-OCS-GE fournie en entrée du processus, et à droite le résultat de notre méthode. Ainsi, on peut voir sur la BD initiale, une zone de superposition entre des objets de type *forêt* et des objets de type *champs*. Dans les deux cas, notre méthode permet de prendre une décision correcte sur ces zones de recouvrement.

Par ailleurs, les zones non couvertes peuvent se limiter à quelques petits espaces situés entre les objets de la BD, ou, dans le cas où l’on dispose d’une image plus grande que la BD initiale, la zone non couverte peut s’étendre sur une surface importante, comme c’est le cas dans le jeu de données utilisé dans ce chapitre (*cf.* Figure 8.2). Or, les résultats présentés ici montrent que la méthode LPN fournit un résultat de classification, ainsi qu’une mesure de confiance associée, sur l’ensemble de la zone couverte par l’image. Ainsi, le travail d’un opérateur pour compléter et étendre la BD sur cette zone, pourra se limiter à l’inspection des zones de faibles confiances (*cf.* zone rouge clair à droite sur la






FIGURE 8.10 – Carte de changements (rouge : changement - blanc : confusion - bleu : non changement). Les zones en rouge correspondent à des « trous » dans la base de données initiale. Seules les 4 classes les plus représentatives (*zones bâties, zones non-bâties, forêts et champs*) et la classe *eau* sont considérés ici.

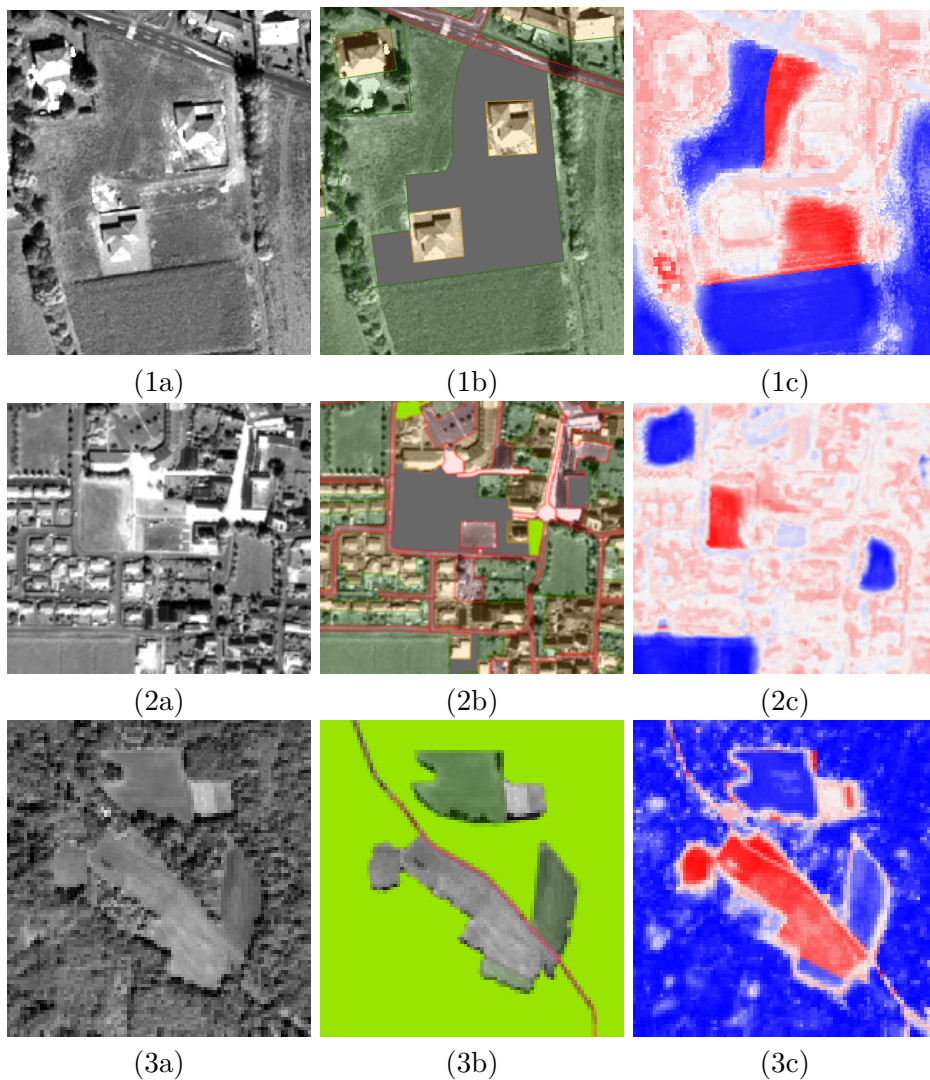


FIGURE 8.11 – Trois zooms sur des zones de changements, pour chacune : (a) l'ortho-image, (b) la BD OCS et (c) la carte de changements.




FIGURE 8.12 – Deux zones d'intérêts sur lesquelles des objets de différentes classes de la BD-OCS-GE se superposent (1a) et (2a). Le résultat de la méthode LPN permet de prendre une décision sur ces zones d'indécision (1b) et (2b).



Figure 8.9; Figure8.13 : en haut pour la complétion et en bas l'extension de la BD).

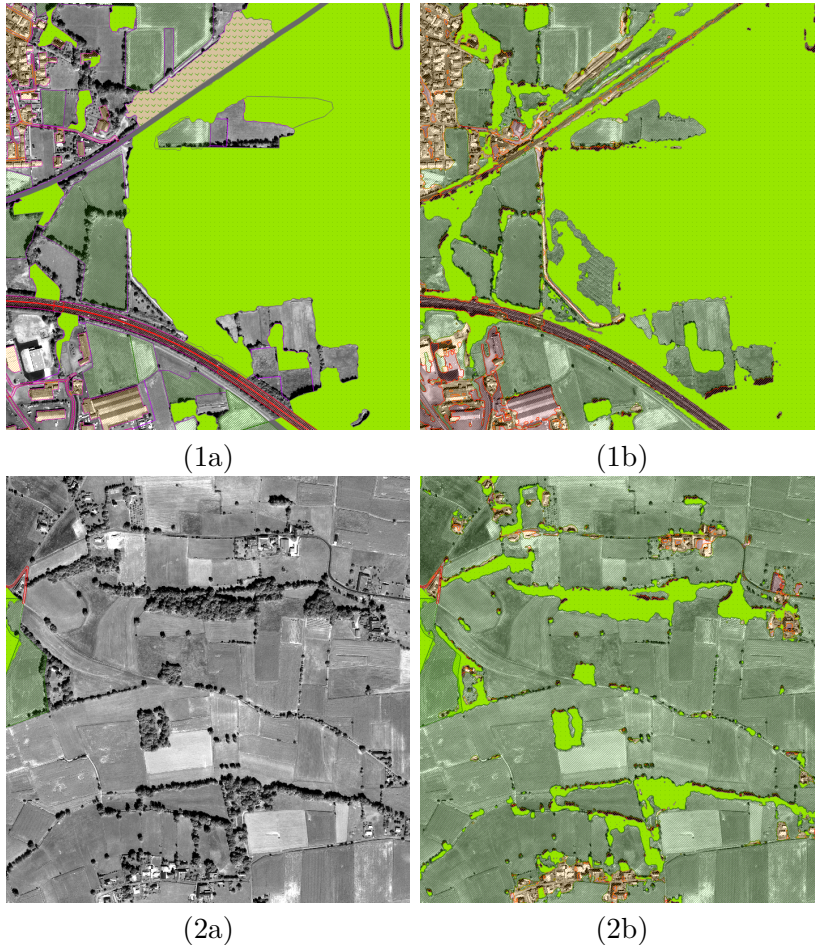


FIGURE 8.13 – Une zone où la BD est incomplète (1a) et le résultat de  $\mathbb{L}\mathbb{P}\mathbb{N}$  sur cette zone (1b), et une autre zone hors de la zone couverte par la BD et le résultat de classification obtenue sur cette zone (2b). Dans les deux cas, la méthode permet de classer correctement les zones non couvertes par la BD initiale.

## 8.4 Étude des temps de traitements

Notre zone d'étude a une surface de  $32 \text{ km}^2$  ( $4 \text{ km} \times 8 \text{ km}$ ), l'image Pléiades contient 128 000 000 pixels et la BD possède 4913 objets (dont seulement les dix plus grands de chaque classe sont utilisés pour l'apprentissage). Sur ce jeu de données, les temps de calcul se répartissent approximativement ainsi :

- 1 jour pour le calcul des attributs ;
- 1/2 jour pour la sélection d'attributs ;

- 1 jour d'apprentissage ;
- 1/2 jour de classification ;
- <1 heure pour la fusion des classifications et le calcul de la carte de probabilité de changement.

Cependant, il est à noter que certaines étapes comme la sélection d'attributs sont indépendantes de la taille de la zone. De plus, nous avons ici calculé un grand nombre d'attributs pour des raisons expérimentales et qu'il n'est absolument pas nécessaire de tous les calculer dans un contexte de production. En effet, comme nous avons pu le voir dans le chapitre 7, que le taux de bonne classification est déjà élevé avec un faible nombre d'attributs (de l'ordre de 10 attributs par classe, cf. Figure 7.3). Ainsi les deux premières étapes peuvent être largement réduites. De plus, la question du passage à l'échelle n'a été traitée que succinctement. Cependant, à ce sujet, il faut distinguer l'apprentissage de la classification. La sélection et l'apprentissage pourra être fait en utilisant plusieurs dalles (réparties aléatoirement sur la zone?), alors que la classification pourra être réalisée en parallèle sur chacune des dalles.

## 8.5 Conclusion

La grande variété d'attributs à disposition permet de s'adapter aux caractéristiques de l'image, l'apprentissage permet l'adaptation aux classes analysées (quelconques) et la redondance des classifications réduit le taux de fausses alarmes. Des classes se discriminent plutôt très bien d'ores et déjà (*végétation, champs, routes*) et les perspectives proposées dans la section 10.3 s'attacheront à améliorer les traitements :

- des classes bien classées mais peu discriminées (*e.g., zones bâties*) : l'introduction de Modèles Numériques de Surfaces, si des données stéréoscopiques sont disponibles, peut aider grandement à cette tâche ainsi qu'une phase d'apprentissage itérative, utilisant ces premières classifications.
- des classes mal classées, principalement dû au fait qu'elles sont composées de peu d'objets, souvent de petite taille.

Ainsi, les résultats présentés dans ce chapitre montrent que la chaîne de traitements  $\mathbb{L}\mathbb{P}\mathbb{N}$  permet de s'adapter à différentes BD d'OCS (nomenclatures plus ou moins détaillées). De plus, les taux de fausses alarmes sont relativement faibles et les temps de calculs pourront être réduits afin d'envisager un passage rapide de la méthode en production. Ainsi, la chaîne de traitements  $\mathbb{L}\mathbb{P}\mathbb{N}$  répond aux attentes exprimées dans la section 1.3. Par ailleurs, comme on a pu le voir dans la sous-section 8.3.3, la chaîne de traitements  $\mathbb{L}\mathbb{P}\mathbb{N}$  apporte une aide intéressante pour l'initialisation de BD d'OCS issue de la fusion de différentes BDs, mais aussi pour la complétion des trous pouvant exister dans la BD, ou l'extension de la couverture d'une telle BD.

# Application à différents jeux de données

---

## Sommaire

---

10.1 Conclusion . . . . .	156
10.2 Contributions et limitations . . . . .	157
10.3 Perspectives d'améliorations et d'applications . . . . .	158
10.3.1 Améliorations des classifications . . . . .	159
10.3.2 Passage à l'échelle . . . . .	160
10.3.3 Applications envisagées . . . . .	162

---

Nous avons pu voir dans le chapitre précédent l'application de la chaîne de traitements  $\mathbb{L}\mathbb{P}\mathbb{N}$  pour la mise à jour de la BD d'OCS-GE de l'IGN à partir d'une unique image satellite THR Pléiades. Dans ce chapitre, nous avons souhaité montrer la polyvalence de la chaîne de traitements  $\mathbb{L}\mathbb{P}\mathbb{N}$  et sa capacité à travailler avec différents types de données de télédétection. Nous nous limitons dans cette thèse à des applications de télédétection mais d'autres domaines en traitement d'image ou plus généralement en analyse de données sont envisageables.

Ainsi, dans un premier temps, nous étudierons le comportement de notre méthode sur des données de télédétection issues de différents capteurs optiques, avec en particulier l'étude de l'influence de la résolution spatiale du capteur sur la qualité des classifications obtenues. Puis, nous introduirons des données images multi-temporelles dans le processus de classification afin d'étudier la pertinence de ce type de données dans le cadre de notre problématique.

## 9.1 Différentes résolutions spatiales

La première étude sur la polyvalence de notre méthode nous a conduit à comparer les résultats obtenus individuellement avec des images satellite optiques à différentes résolutions (1,5 m pour SPOT 6 et 5 m pour RapidEye), au résultat obtenu avec les données Pléiades, sur la même zone d'expérimentation que dans le chapitre précédent (*cf.* section 8.1).

### 9.1.1 Présentation des données

La première image a été acquise par le satellite Pléiades en septembre 2012 (*cf.* 9.1a), décrite dans le chapitre précédent. La seconde image a été acquise en avril 2013, par le satellite SPOT 6 (*cf.* 9.1b). L'ortho-image utilisée est ré-échantillonnée à une résolution de 1,5 m en panchromatique et de 6 m en multi-spectrale (bleu, vert, rouge, proche infrarouge) et a une taille de 5 333×2 667 pixels.

Enfin, la troisième image a été acquise en septembre 2011, par le satellite RapidEye (*cf.* 9.1c). Nous utiliserons l'ortho-image ré-échantillonnée à 5 m de résolution, comportant 5 canaux (bleu, vert, rouge, red-edge, proche infrarouge). Ce satellite a la particularité de posséder un canal red-edge situé entre le rouge et le proche infrarouge (690 - 730 nm), qui permet de discriminer efficacement différents types de végétation [Le Bris et al., 2013] (*cf.* Figure 9.2). L'image utilisée a une taille de 1 600×800 pixels.

La BD-OCS utilisée est la même que celle décrite dans le chapitre précédent (*cf.* section 8.1). Les classifications reposent sur un ensemble d'attributs issus des familles suivantes : une centaine d'attributs spectraux, des attributs de texture de type Haralick calculés sur les canaux panchromatique (pour SPOT 6), red-edge (pour RapidEye) et rouge et proche-infrarouge (pour les deux images) et les attributs SFS. Ainsi, 165 attributs sont calculés pour SPOT 6 et 162 pour RapidEye.





(a) Pléiades, septembre 2013



(b) SPOT 6, avril 2013



(c) RapidEye, septembre 2011

FIGURE 9.1 – Extrait de l'image Pléiades acquise en septembre 2013 (a), de l'image SPOT 6 acquise en avril 2013 (b) et de l'image RapidEye acquise en septembre 2011 (c) sur la zone de Tarbes.




FIGURE 9.2 – Extrait de l’image RapidEye, en composition colorée R - Red-Edge - PIR, acquise en septembre 2011 sur la zone de Tarbes.

### 9.1.2 Résultats

Comme pour les expérimentations précédentes, nous avons utilisé un classifieur de type Forêts Aléatoires (FA) et les fusions de classifications sont réalisées par la méthode RWF.

Les taux de bonne classification obtenus (*cf.* Tableau 9.1) montrent l’apport de la THR du satellite Pléiades. En effet, les résultats de ce dernier ont une avance nette sur ceux des deux autres satellites : 0,67 pour Pléiades, alors que SPOT 6 et RapidEye sont sous les 0,5. Ces deux capteurs obtiennent des taux de bonne classification similaires, respectivement 0,47 et 0,49 pour SPOT 6 et RapidEye. Ainsi, on peut noter que malgré sa plus faible résolution spatiale, l’ajout du canal red-edge permet à RapidEye d’obtenir des résultats de classification comparables à ceux de SPOT 6.

Capteur	Pléiades	SPOT 6	RapidEye
Précision	<b>0,67</b>	0,47	0,49

Tableau 9.1 – Comparaison des taux de bonne classification (précision) de la méthode appliquée sur trois images issues de trois capteurs différents (Pléiades, SPOT 6 et RapidEye).

Par ailleurs, le détail des précisions producteurs et utilisateurs pour chaque classe est donné dans le Tableau 9.2. Comme pour les données Pléiades, les résultats sur ces deux satellites donnent de bons résultats de classifications sur les 4 classes majoritaires sur la zone (représentant 96 % de la couverture de la zone). Contre-intuitivement, les résultats des classifications, en terme de précision producteur, sont meilleurs avec SPOT 6 et RapidEye sur les classes *bâti* et *route*, alors que Pléiades, malgré sa forte résolution, obtient des résultats légèrement moins bons. Cependant, la précision utilisateur sur le thème *route*



tourne à l'avantage de Pléiades. Ceci s'explique par la confusion existant entre ces deux classes sur les classifications issues de SPOT 6 et RapidEye (*cf.* sous-section 9.1.3). De plus, on peut noter que RapidEye, grâce à son canal supplémentaire dans le red-egde, obtient une meilleure précision utilisateur sur le thème *forêt* et que la résolution de SPOT 6 semble être un bon compromis pour la classification des *zones bâties*. Pléiades obtient de son côté de très bons résultats sur les thèmes *formations herbacées* et *peuplement de feuillus* autant en terme de précision utilisateur que producteur. En particulier, la grande résolution de Pléiades permet de discriminer finement les espaces verts urbains (composant la classe *formations herbacées* avec les champs). Sur les images RapidEye et SPOT 6, le thème *formations herbacées* a une faible précision utilisateur. En effet il est confondu avec le thème *bâti* (*cf.* sous-section 9.1.3). Ceci s'explique par le fait que ce thème contient les champs et également les espaces verts urbains. Ces derniers sont souvent confondus avec la classe *bâti*. De plus, sur les données SPOT 6, la classification de ce thème a également une faible précision producteur : les vrais champs ne sont pas bien classés par ce jeu de données. Par ailleurs, les thèmes peu représentés, que l'on avait du mal à classer avec Pléiades, obtiennent des résultats encore plus décevants avec les images SPOT 6 et RapidEye.

### 9.1.3 Étude visuelle

Afin de compléter l'étude des résultats chiffrés, nous proposons une étude visuelle de la classifications des thèmes principaux (*bâti*, *route*, *champ* et *forêt* sur deux sous-zones caractéristiques, issues de notre zone d'étude (*cf.* Figures 9.3 et 9.4). La première zone est située en périphérie de Tarbes sur une région semi-urbaine et est composée de maisons isolées, de routes, de champs et de haies (*cf.* Figure 9.3a). Pour la classe *bâti*, les trois classifications (Pléiades : 9.3b, SPOT 6 : 9.3c et RapidEye : 9.3d) permettent de faire ressortir l'ensemble des éléments présents sur la zone. Cependant, la classification RapidEye englobe également certains champs et certaines routes et est donc moins précise. La classification SPOT 6 est plus confiante dans ses résultats que celle issue des données Pléiades (les valeurs des probabilités d'appartenance à la classe sont plus fortes), ce qui confirme les résultats chiffrés obtenus précédemment. Sur le thème *route*, la classification des données Pléiades (9.3e) est celle obtenant les meilleurs résultats : elle permet de classer finement la quasi-intégralité des routes présentes sur la zone. Cependant, une faible confusion avec les zones bâties subsiste encore. La classification RapidEye (9.3g) n'arrive pas à discriminer la route des bâtiments, alors que la classification sur les données SPOT 6 (9.3f) n'arrive pas à discriminer certains champs et certains bâtiments. Les images Pléiades permettent de discriminer finement le thème *peuplement de feuillus* (9.3h), en particulier en faisant ressortir les arbres présents dans les zones pavillonnaires et les haies. La résolution de RapidEye, ne permet pas de discriminer la végétation présente dans ces zones pavillonnaires (9.3j). Cependant, les haies suffisamment larges sont bien discriminées. Enfin, les données SPOT 6 échouent ici à discrimi-

	<b>Pléiades</b>	<b>SPOT 6</b>	<b>RapidEye</b>
	<b>Précisions utilisateur (Exactitude)</b>		
<i>Zones bâties (*)</i>	0,21	<b>0,56</b>	0,36
<i>Zones non bâties (*)</i>	<b>0,4</b>	0,35	0,25
<i>Zones à matériaux minéraux</i>	0,16	0,06	0,05
<i>Surfaces d'eau</i>	0,46	0,23	0,02
<i>Peuplement de feuillus (*)</i>	0,86	0,93	<b>0,94</b>
<i>Autres formations arborées</i>	0,81	0,02	0,02
<i>Formations arbustives</i>	0	0,01	0,01
<i>Autres formations ligneuses</i>	0,39	0,02	0,01
<i>Formations herbacées (*)</i>	<b>0,7</b>	0,47	0,58
Moyenne	0,44	0,29	0,25
Moyenne (*)	0,54	<b>0,58</b>	0,54
	<b>Précisions producteur (Rappel)</b>		
<i>Zones bâties (*)</i>	0,51	0,71	<b>0,95</b>
<i>Zones non bâties (*)</i>	0,65	0,52	<b>0,89</b>
<i>Zones à matériaux minéraux</i>	0,19	0,56	0,87
<i>Surfaces d'eau</i>	0,35	0,80	0,78
<i>Peuplement de feuillus (*)</i>	<b>0,94</b>	0,85	0,82
<i>Autres formations arborées</i>	0,01	0,43	0,93
<i>Formations arbustives</i>	0,16	0,03	0,52
<i>Autres formations ligneuses</i>	0,05	0,84	0,89
<i>Formations herbacées (*)</i>	<b>0,96</b>	0,12	0,83
Moyenne	0,42	0,54	0,83
Moyenne (*)	0,77	0,55	<b>0,87</b>

Tableau 9.2 – Détails des précisions utilisateur et producteur par classe obtenues sur trois capteurs différents : Pléiades, SPOT 6 et RapidEye.

miner les éléments de ce thème.

La seconde zone est couverte uniquement de champs et de forêts (*cf.* Figure 9.4). Sur cette zone, les données RapidEye (9.4d et 9.4g) sont les plus à même de discriminer les thèmes *champs* et *forêts*. De son côté, Pléiades permet une classification plus fine spatialement, que l'on peut constater en bordure de forêts et sur les arbres isolés dans les champs qui sont correctement classés (9.4b). Enfin, la classification sur les données SPOT 6 est correcte sur le thème *forêt* (9.4c), mais n'est pas très confiante sur le thème *champs* (9.4f).

## 9.2 Données multi-temporelles

### 9.2.1 Présentation des données

Par ailleurs, nous disposons de deux autres images RapidEye, acquises en avril 2011 à dix jours d'intervalle (*cf.* Figure 9.5). Ainsi, nous proposons différentes adaptations de la chaîne de traitements  $\mathbb{L}\mathbb{P}\mathbb{N}$  afin de traiter des données multi-temporelles et nous comparons ces différents scénarii, pour juger de leur pertinence.

### 9.2.2 Méthodes utilisées

Afin d'utiliser ces trois images conjointement, nous proposons trois méthodes, consistant en trois fusions à différents niveaux de la chaîne de traitements  $\mathbb{L}\mathbb{P}\mathbb{N}$  (*cf.* Figure 9.6), ces trois méthodes seront comparées aux résultats obtenus avec une seule image RapidEye (celle ayant obtenu les meilleurs résultats de classification).

La première méthode consiste à sélectionner de manière conjointe les 20 meilleurs attributs calculés séparément sur les trois dates disponibles, cette méthode sera appelée par la suite *sélection globale*. Nous avons choisi le nombre de 20 attributs, car il a fourni de bons résultats sur les données Pléiades, mais une étude de la pertinence de ce choix sur les données RapidEye serait à mener.

La seconde méthode consiste à sélectionner séparément les 7 meilleurs attributs de chaque date et à utiliser ces 21 attributs pour les classifications. Nous avons choisi 7 attributs afin d'avoir *in fine* le même nombre d'attributs que pour la méthode de *sélection globale*. Cette méthode sera nommée *sélection par date*.


La troisième méthode consiste à réaliser l'ensemble des classifications par objets sur les trois dates séparément, on obtient donc 3 classifications pour chaque objet inspecté. Enfin, les classifications sont fusionnées au niveau de chaque classe, de la même manière que dans la méthode classique (ici la méthode RWF). Cette dernière méthode de fusion est appelée *fusion niveau classe*.




(a) Image Pléiades



(b) Classe *bâti* - Pléiades




(c) Classe *bâti* - SPOT 6




(d) Classe *bâti* - RapidEye



(e) Classe *route* - Pléiades




(f) Classe *route* - SPOT 6




(g) Classe *route* - RapidEye



(h) Classe *forêt* - Pléiades



(i) Classe *forêt* - SPOT 6




(j) Classe *forêt* - RapidEye


FIGURE 9.3 – Détails des classifications sur les thèmes *bâti*, *route* et *forêt*, obtenues à partir des données Pléiades, SPOT 6 et RapidEye. Chaque image est colorée de blanc : forte appartenance au thème à noir : faible appartenance au thème.



(a) Image Pléiades




(b) Classe *forêt* - Pléiades




(c) Classe *forêt* - SPOT 6



(d) Classe *forêt* - RapidEye



(e) Classe *champ* - Pléiades



(f) Classe *champ* - SPOT 6



(g) *champ* - RapidEye

FIGURE 9.4 – Détails des classifications sur les thèmes *forêt* et *champs*, obtenues à partir des données Pléiades, SPOT 6 et RapidEye. Chaque image est colorée de blanc : forte appartenance au thème à noir : faible appartenance au thème.





(a) RapidEye, le 4 avril 2011



(b) RapidEye, le 16 avril 2011



(c) RapidEye, le 6 septembre 2011

FIGURE 9.5 – Extrait des images RapidEye acquises en avril 2011 (a et b) et septembre 2011 (c) sur la zone de Tarbes.




FIGURE 9.6 – Schéma comparatif des différentes méthodes de fusion : (a) la *sélection globale* des attributs issus des différentes dates, (b) la *sélection par date*, (c) la *fusion niveau classe* et (d) le choix de la *meilleure date* (aucune fusion).

### 9.2.3 Résultats

Les taux de bonne classification pour les différents scénarii sont compris entre 0,54 et 0,66 (*cf.* Tableau 9.3). Contre intuitivement, c’est l’utilisation d’une seule image qui donne les meilleurs résultats, alors que l’introduction des autres dates abaisse légèrement la qualité des résultats. Le choix de la meilleure classification (*meilleure date*) permet de mettre de côté les classifications des autres dates, qui sont ici de beaucoup moins bonne qualité. Enfin, les méthodes de fusion ne parviennent pas à rattraper la confusion introduite par ces deux dates supplémentaires.

Fusion	Précision
<i>Meilleure date</i>	<b>0,66</b>
<i>Sélection globale</i>	0,54
<i>Sélection par date</i>	0,55
<i>Fusion niveau classe</i>	0,57

Tableau 9.3 – Comparaison des taux de bonne classification (précision) obtenus par les différentes méthodes de fusion de données multi-temporelle.

Le détail des précisions utilisateur et producteur, pour chaque classe de la BD et pour chaque méthode de fusion proposée, est donné dans le Tableau 9.4. Les résultats obtenus pour la *meilleure date* (meilleurs taux de bonnes classification après l’étape de prise de décision), ne sont pas forcément les meilleurs en terme de précisions utilisateur et producteur. Par exemple, seul le thème *formations herbacées* a une meilleure précision utilisateur que les autres méthodes et seuls les thèmes *zones non bâties* et *formations herbacées* ont une meilleure précision producteur. Dans les autres cas, la *sélection globale* et la *fusion niveau classe* améliorent généralement la précision utilisateur, alors que la *sélection par date* améliore plutôt la précision producteur.

### 9.2.4 Analyse visuelle

Nous avons ensuite réalisé une étude visuelle sur une partie de l’image contenant les 4 thèmes majoritaires de la BD (*bâti*, *route*, *forêt* et *champ*). Les résultats sont regroupés dans la Figure 9.7, avec l’image RapidEye (acquise en septembre) correspondant à cette zone (9.7a).

Sur le thème *bâti*, la méthode par *sélection globale* (9.7c) semble donner des résultats plus précis : il y a moins de confusion avec les zones voisines des bâtiments (pixels mélangés), qu’avec les autres méthodes de fusions (9.7b, 9.7d et 9.7e). Cependant, le thème *bâti* est toujours confondu avec le thème *route*. Les mêmes remarques peuvent être faites sur le thème *route* (9.7f à 9.7i).

Pour le thème *forêt*, les différentes méthodes donnent des résultats assez proches. On peut noter que la *meilleure date* (9.7j) et la méthode de *sélection*

	<i>Meilleure date</i>	<i>Sélection globale</i>	<i>Sélection par date</i>	<i>Fusion niveau classe</i>
	Précisions utilisateur (Exactitude)			
<i>Zones bâties (*)</i>	0,36	<b>0,4</b>	0,33	0,37
<i>Zones non bâties (*)</i>	0,25	0,25	0,19	<b>0,26</b>
<i>Zones à matériaux minéraux</i>	0,05	0,04	0,04	0,05
<i>Surfaces d'eau</i>	0,02	0,04	0,03	0,05
<i>Peuplement de feuillus (*)</i>	0,94	<b>0,98</b>	0,96	<b>0,98</b>
<i>Autres formations arborées</i>	0,02	0,02	0,02	0,01
<i>Formations arbustives</i>	0,01	0,01	0,01	0,01
<i>Autres formations ligneuses</i>	0,01	0,01	0,00	0,01
<i>Formations herbacées (*)</i>	<b>0,58</b>	0,55	0,57	0,56
Moyenne	0,25	0,25	0,24	0,26
Moyenne (*)	<b>0,54</b>	<b>0,54</b>	0,51	<b>0,54</b>
	Précisions producteur (Rappel)			
<i>Zones bâties (*)</i>	0,96	0,92	<b>0,97</b>	0,95
<i>Zones non bâties (*)</i>	<b>0,89</b>	0,88	0,88	0,86
<i>Zones à matériaux minéraux</i>	0,87	0,91	0,91	0,88
<i>Surfaces d'eau</i>	0,78	0,79	0,76	0,77
<i>Peuplement de feuillus (*)</i>	0,82	0,80	<b>0,85</b>	0,80
<i>Autres formations arborées</i>	0,93	0,91	0,93	0,96
<i>Formations arbustives</i>	0,52	0,38	0,45	0,57
<i>Autres formations ligneuses</i>	0,89	0,91	0,95	0,90
<i>Formations herbacées (*)</i>	<b>0,83</b>	0,63	0,72	0,69
Moyenne	0,83	0,79	0,82	0,82
Moyenne (*)	<b>0,87</b>	0,81	0,85	0,83

Tableau 9.4 – Détails des précisions utilisateur et producteur par classe obtenues avec les différentes méthodes de fusions.

*par date* (9.7l) ont d'une part une meilleure confiance sur les zones de forêts (zones blanches à droite de l'image) et d'autre part permettent de discriminer les haies (présentes sur la partie gauche de l'image).

Enfin, pour le thème *champs* (9.7n à 9.7q), la même analyse que celle effectuée dans la sous-section 9.1.2 peut être faite : ce thème est confondu avec les thèmes *bâti* et *route* à cause de la présence d'objets de type « espace vert urbain ».

### 9.3 Conclusion

L'introduction de différentes images satellite issues de capteurs variés (différentes résolutions spatiales, différentes bandes spectrales) et d'une série temporelle, nous ont permis de montrer la polyvalence de notre chaîne de traitements. En effet, sur ces différents jeux de données, notre méthode a été capable de s'adapter afin de discriminer au mieux les thèmes présents dans la BD d'OCS.

Par ailleurs, notre méthode a permis de juger de la pertinence de ces différents capteurs pour la discrimination des différents thèmes de cette BD. Ainsi, nous avons pu voir que le capteur RapidEye est très performant pour discriminer les classes de forêt, et ce, grâce à son canal red-edge. De son côté, l'image SPOT 6 obtient de bons résultats pour le thème *zone bâtie*, en gardant malgré tout de la confusion avec les routes.


Enfin, la résolution des données Pléiades permet de discriminer finement les routes (même si une confusion avec les bâtiments existe toujours) et également les *zones herbacées* (essentiellement les champs et les espaces verts urbains). De plus, les données multi-temporelles utilisées (seulement trois dates dont deux très proches) ne nous permettent pas de juger de leurs pertinences par rapport à l'utilisation d'une seule date. L'étude d'une série temporelle contenant plus d'images (des différentes saisons de l'année) serait souhaitable.

Finalement, nous avons vu que les différents capteurs permettent chacun de discriminer des thèmes spécifiques. De plus des expérimentations sont en cours sur des données LIDAR et RADAR disponibles sur la même zone. Ces données nous permettront également d'envisager des classifications multi-capteurs, afin de tirer profit de la spécificité de chacune des données disponibles et d'améliorer encore la précision des classifications obtenues.





(a) Image RapidEye



(b) *bâti* - *SF*

(c) *bâti* - *SG*

(d) *bâti* - *SD*

(e) *bâti* - *FC*




(f) *route* - *SF*

(g) *route* - *SG*

(h) *route* - *SD*

(i) *route* - *FC*



(j) *forêt* - *SF*

(k) *forêt* - *SG*

(l) *forêt* - *SD*

(m) *forêt* - *FC*



(n) *champs* - *SF*

(o) *champs* - *SG*

(p) *champs* - *SD*

(q) *champs* - *FC*

FIGURE 9.7 – Détails des classifications sur les thèmes *bâti*, *route*, *forêt* et *champs*, obtenues avec les différentes méthodes de fusion de données multi-temporelle : *meilleure date* (*SF*), *sélection globale* (*SG*), *sélection par date* (*SD*) et *fusion niveau classe* (*FC*). Chaque image est colorée de blanc : forte appartenance au thème à noir faible appartenance au thème.





**Cinquième partie**

**Conclusion et perspectives**



# Conclusion et perspectives

---

## 10.1 Conclusion

L'objet de cette thèse était de développer une méthode automatique de mise à jour de BDs d'OCS-GE, à partir d'une image satellite THR monoscopique (afin de réduire les coûts d'acquisition), tout en garantissant la robustesse de la mise à jour.

Les méthodes existantes en télédétection pour la mise à jour de BD d'OCS reposent généralement, sur un ensemble de méthodes spécifiques à chaque thème de la BD (*e.g.*, routes, bâti, ...), et/ou sur la méthode classique d'apprentissage / classification. Dans le premier cas, les méthodes dépendent des thèmes d'une BD spécifique et ne peuvent pas être adaptées facilement à d'autres thèmes ou nomenclatures. Dans le second, les résultats souffrent d'inconvénients liés principalement à l'inhomogénéité des thèmes. Par ailleurs, malgré l'utilisation croissante de méthodes basées région, nous avons vu dans les méthodes d'extraction de caractéristiques morphologiques et de textures (calculées sur un voisinage de chaque pixel de l'image) un potentiel intéressant pour les images THR et qui s'est avéré concluant.

Ainsi, notre méthode est fondée sur un algorithme central d'apprentissage multi-niveaux MLMOL, qui permet de prendre en compte au mieux les apparences, éventuellement multiples, de chaque thème de la BD, sous réserve de l'existence de suffisamment d'objets dans chacun des thèmes de cette dernière. Cet algorithme est complètement indépendant du choix du classifieur et des attributs utilisés et peut donc être appliqué sur des jeux de données très variés. De plus, la multiplication de classifications permet d'améliorer la robustesse de la méthode, en particulier sur des thèmes ayant des apparences multiples.

De plus, nous avons intégré la méthode MLMOL dans une chaîne de traitements capable, d'une part de s'adapter automatiquement aux différents thèmes pouvant exister et, d'autre part, d'être robuste à l'existence de thèmes inhomogènes, reposant sur un ensemble de classifications supervisées et automatiques. La chaîne de traitements  $\mathbb{I}\mathbb{P}\mathbb{N}$ , repose sur l'extraction d'un très grand nombre d'attributs spatiaux et spectraux issus de la littérature, délivrant des informations spectrales, mais également morphologiques et de texture. Ce très grand nombre d'attributs, couplé à une sélection d'attributs par thème, permet d'obtenir des classifications de qualité sur des thèmes très variés. Enfin, notre méthode fournit une carte de probabilité de changement, permettant de garder une mesure de la confiance dans le résultat obtenu et ainsi permettre de diriger le travail d'un opérateur, soit sur les zones de changement certain, soit sur les zones d'incertitude. Nous avons validé notre méthode au fur et à mesure de son développement sur différents jeux de données simulés ou générés à partir d'images Pléiades.

En particulier, nous avons pu observer que les attributs les plus pertinents pour la classification d'images THR sont les attributs prenant en compte le voisinage de chaque pixel et pouvant s'adapter à l'échelle d'observation la plus appropriée. Plus précisément, les profils morphologiques [Dalla Mura et al., 2010]

permettent cette double analyse et dans une moindre mesure les attributs d'occurrence [van de Sande et al., 2010], les attributs géométriques [Huang et al., 2007] et les textures d'Haralick tirent également profit de la résolution de ce type d'image. Enfin, notre étude montre qu'une centaine d'attributs différents (sur les environ 900 calculés) semblent suffisant pour discriminer finement les différents thèmes de la BD OCS considérée.

Nous avons alors appliqué avec succès notre méthode à une image Pléiades, sur une zone à proximité de Tarbes (65) décrite par la BD-OCS-GE de l'IGN. Les résultats obtenus montrent, d'une part que la richesse des images Pléiades (en termes de résolution submétrique et de dynamique) permet d'avoir des résultats de classification de bonne qualité, même sur des thèmes comme les routes et les bâtiments qui nécessitent habituellement des méthodes spécifiques, en utilisant des attributs de texture et de forme (profil morphologique, SFS, ...). En effet, ces attributs sont très adaptés à la résolution des images Pléiades. D'autre part, ces résultats montrent que la méthode proposée permet de fournir des indicateurs pertinents de changement sur la zone.

Nous avons montré par ailleurs que notre méthode peut fournir une aide précieuse à la constitution de BD d'OCS issues de la fusion de différentes BDs. En effet, notre méthode a la capacité de prise de décisions lorsque la fusion de BDs génère des zones de recouvrement, phénomène courant notamment lorsque les données proviennent de sources différentes et de spécifications différentes. De plus, notre méthode permet également de compléter d'éventuels lacunes dans la zone de couverture de la BD générée, mais aussi d'étendre cette couverture sur l'emprise d'une image couvrant une zone plus large.

Enfin, la chaîne de traitements  $\mathbb{I}\mathbb{P}\mathbb{N}$  a été appliquée à différents jeux de données de télédétection afin de valider sa polyvalence et de juger de la pertinence de ces données. Les résultats ont montré sa capacité d'adaptation aux données de différentes résolutions utilisées (Pléiades à 0,5 m, SPOT 6 à 1,5 m et RapidEye à 5 m). De plus, nous avons constaté l'intérêt du canal red-edge de RapidEye pour la discrimination du thème forêts, le bon compromis de résolution que fournit SPOT 6 pour le thème *zones bâties* et l'apport de la THR de Pléiades pour discriminer des thèmes précis comme les routes ou les espaces verts urbains. Chaque capteur possède ces avantages et ces inconvénients, ainsi il faudrait, quand les données sont disponibles, faire une fusion de classification entre différents capteurs.

## 10.2 Contributions et limitations

Notre principale contribution est la proposition d'une méthode générique de multiplication des classifications, nommée MLMOL, qui permet, d'une part, la **classification de thèmes complexes possédant différentes apparences** et, d'autre part, un **apprentissage à partir de données partiellement fausses** (pouvant venir d'un éventuel décalage entre l'image et la BD).

La seconde contribution de ce travail est l'intégration de la méthode précédente dans une chaîne de traitements permettant de s'**adapter automatique-ment aux thèmes** de la BD à mettre à jour et de fournir des **indicateurs de changement**, tout en modérant sa réponse en fonction d'une **mesure de confiance** issue du processus de classification.

Par ailleurs, nous avons pu étudier les capacités des images THR Pléiades, en termes de possibilité d'extraction d'information. En particulier, nous montrons que les attributs morphologiques (*cf.* sous-section 3.3.2) et les attributs de forme (*cf.* sous-section 3.3.1) permettent de tirer profit de la résolution submétrique de ce type d'images. Cependant, nous montrons également les limites de l'utilisation de données non-stéréoscopiques. En effet, bien que majoritairement bien classé, le thème *bâti* est peu discriminé du thème *non-bâti* de la BD-OCS-GE (qui contient principalement les routes et les parkings). En particulier, même les attributs morphologiques ou de forme, ne permettent pas de discerner les grands bâtiments (type hangars industriels ou commerciaux) des parkings. Ce type de problème ne pourra pas être réglé sans l'utilisation d'une donnée altimétrique (issue, par exemple, d'images stéréoscopiques : MNS), permettant de distinguer les éléments du sol et du sur-sol.

De plus, notre méthode, afin de gagner en généralité et en robustesse, nécessite, d'une part, de calculer un grand nombre d'attributs et, d'autre part, de multiplier les classifications. Par conséquent, les temps de calcul liés à ces différentes étapes restent viables, mais devront être améliorés afin d'envisager son passage à l'échelle. Ainsi, nous avons vu dans cette section, ce dont notre méthode était capable, ses points forts, ainsi que ses faiblesses. Nous proposerons donc dans la section suivante, d'une part un ensemble d'idées d'amélioration qui pourrait permettre de réduire les points faibles de la méthode et d'autre part les différentes applications connexes, rendues possibles par notre méthode.

### 10.3 Perspectives d'améliorations et d'applications

L'étude de la littérature et les expérimentations que nous avons réalisées nous ont permis de dégager un certain nombre d'éléments afin d'améliorer la méthode proposée en termes de qualité de classification, de temps de calculs, de généralité (utilisation de différents capteurs) et de possibilité d'interaction avec un opérateur. Par ailleurs, nous proposons une analyse de la méthode afin de discuter des possibilités de son passage à l'échelle (image Pléiades sur l'équivalent d'un département français voir une couverture SPOT 6 France entière annuelle). Enfin, nous proposons différentes applications rendues possibles grâce à la méthode MLMOL et à la chaîne de traitements  $\mathbb{P}\mathbb{P}\mathbb{N}$ .

### 10.3.1 Améliorations des classifications

#### Introduction d'information haut-niveau

Dans nos travaux, seul une information bas niveau directement extraite de l'image sous forme d'attributs a été utilisée. Cependant, deux types d'informations peuvent être extraits de la BD et utilisés par la méthode de classification afin d'en améliorer les résultats : la répartition spatiale des objets les uns par rapport aux autres et une information de hiérarchisation des thèmes. Dans le premier cas, il peut s'agir d'introduire des noyaux spécifiques dans les SVM [Camps-Valls et al., 2006, 2010; Fauvel et al., 2012], d'une information de co-occurrence des classes [Ladicky et al., 2010], d'une optimisation post-classification par un algorithme de type marche aléatoire étendue (*extended random walker*) [Kang et al., 2015], ou encore d'algorithme mêlant de l'information locale et régionale [Fröhlich et Bach, 2013; Montoya-Zegarra et al., 2014]. Une utilisation de l'information de hiérarchisation des classes est proposée dans [Tuia et Muñoz Marí, 2011].

#### Amélioration de l'adaptabilité

Notre méthode a été validée sur des zones peu étendues, et pourrait souffrir sur des zones plus larges (départements, régions) d'un changement d'apparences des objets dû par exemple à différentes illuminations, à des natures de sol différentes (*e.g.*, humidité, altitude) ou à des changements du paysages (matériaux des toits, différentes cultures). Bruzzone et Persello [2010] évoquent deux méthodes d'apprentissage, émergeant dans la littérature ces dernières années : l'apprentissage semi-supervisé (*semi-supervised learning*) et l'apprentissage actif (*active learning*). Les deux méthodes consistent à enrichir itérativement l'ensemble d'apprentissage à partir des résultats précédents de classification, la première le réalisant automatiquement [Muñoz Marí, 2010] et la seconde en ajoutant des observations provenant d'un ensemble d'apprentissage plus large (pouvant être un opérateur) [Tuia et al., 2011]. Ces méthodes pourraient permettre de modifier les classifications automatiquement au fur et à mesure de l'évolution des territoires couverts.

#### L'avènement du multi-capteurs

En appliquant notre méthode sur différents capteurs individuellement, nous avons pu constater les différences de résultats de ces capteurs suivant les thèmes étudiés (*cf.* chapitre 9). Ce constat semble partagé par l'ensemble de la communauté de la télédétection et un grand nombre de méthodes multipliant les sources d'informations sont apparues ces dernières années [Smarandache et Dezert, 2004; Zhang, 2010; Inglada, 2011]. Or, nous avons montré que notre méthode peut être facilement adaptée à l'utilisation de série temporelle, et nous pensons qu'elle peut l'être similairement avec des données multi-capteurs.



## Interaction avec un opérateur

L'opérateur est dans la majorité des cas nécessaire pour atteindre les spécifications de qualité opérationnelle attendues par un client ou par un opérateur de référence. Et concevoir une méthode complètement automatique est forcément entachée d'erreurs, car l'œil d'un expert apporte toute sa connaissance et éventuellement des informations complémentaires (autres sources de données, relevés terrains, ...). Par conséquent, la méthode  $\mathbb{L}\mathbb{P}\mathbb{N}$  a été conçue de manière à fournir un certain nombre d'indicateurs sur la qualité des classifications et ainsi permettre une interaction entre un opérateur (expert) et l'algorithme. Nous détaillerons ici, deux interactions possibles : une première directement réalisable et une seconde nécessitant une adaptation mineure de la méthode.

Dans son état actuel, la chaîne de traitements  $\mathbb{L}\mathbb{P}\mathbb{N}$  fournit une carte de changements pondérée par une mesure de confiance. Cette valeur de confiance permet déjà de cibler le travail d'un opérateur, soit sur des zones où la méthode a une faible confiance, soit sur les zones à forte probabilité de changement. Ainsi, une méthode interactive fondée sur ce principe et couplée à une interface utilisateur interactive permettrait un gain de productivité important en réduisant les zones à inspecter (par exemple, de l'ordre de 90 % de réduction pour les zones d'incertitude). La première interaction proposée prend uniquement en compte le résultat final de la méthode, mais une vraie interaction au cours du déroulement de celle-ci pourrait également être introduite. Ainsi, la méthode d'apprentissage MLMOL pourrait générer un certain nombre d'alertes, comme la détection en amont des objets modifiés ou prévenir d'un éventuel problème sur les données (comme un décalage entre la BD et l'image). Ces alertes pourraient être traitées par un opérateur afin de guider la méthode dans le processus de fusion par classe, et ainsi, d'en améliorer les résultats à la manière des méthodes d'apprentissage actif [Settles, 2010], tout en prenant en compte la confiance de l'utilisateur dans les informations qu'il fournit [Tuia et Munoz-Mari, 2013].

### 10.3.2 Passage à l'échelle

La tendance actuellement est à la production et la diffusion toujours plus massive de données, par exemple, une couverture de la France entière chaque année par le satellite SPOT 6 est d'ores et déjà planifiée à l'IGN. Face à l'afflux d'une telle quantité de données, les méthodes actuelles de traitements d'images et d'extractions d'informations devront être adaptées. C'est le cas en particulier de la chaîne de traitement  $\mathbb{L}\mathbb{P}\mathbb{N}$ . Ainsi, nous discuterons ici des possibilités de notre méthode et des adaptations envisagées afin de permettre facilement de traiter de telles quantités de données.

### Analyse des capacités de la méthode

Dans son état actuel, notre méthode a permis d'analyser une zone de 32 km<sup>2</sup> (4 km × 8 km) en moins de 4 jours. Cependant, ces temps de calculs ne peuvent

pas être extrapolés directement sur une surface plus grande. En effet, certaines étapes, comme la sélection d'attributs, sont indépendantes de la taille de la zone, alors que d'autres étapes, comme la réalisation des multiples classifications, sont massivement parallélisables dans la mesure où elles sont complètement indépendantes les unes des autres. Malgré tout, le point le plus chronophage de notre méthode est ce nombre important de classifications à réaliser. Ainsi, de notre point de vue, outre les améliorations purement techniques (parallélisation des calculs et leur répartition sur différents ordinateurs), deux points sont à étudier pour faciliter le passage à l'échelle de notre méthode et sont décrits dans le paragraphe suivant : la réduction de la surface traitée par chaque classifieur (classification locale) et la réduction du nombre de classifications par objet.

### **Propositions d'adaptations**

Deux propositions sont faites ici afin de permettre le passage à l'échelle de notre méthode, en limitant les temps de calculs et en s'adaptant localement grâce à la BD à mettre à jour.

**Adaptation locale** La première idée est de découper le travail à réaliser sur une grande zone en plusieurs sous-problèmes locaux. Ainsi, la sélection des attributs et la méthode MLMOL seraient réalisées sur une zone limitée de l'image. Cette adaptation apporterait deux avantages. D'une part, chaque zone pourrait être traitée de manière indépendante et donc la capacité de parallélisation de la méthode serait augmentée. D'autre part, la qualité des classifications pourrait être améliorée car les objets d'un même thème ont des apparences moins hétérogènes sur une zone plus réduite spatialement. Les principaux paramètres à introduire seront la taille de la zone à inspecter et la zone de recouvrement entre les deux zones traitées. Ces paramètres pourront être adaptés localement en étudiant la corrélation entre la classification obtenue et la BD ou en réalisant une segmentation grossière de l'image (recherche de grandes zones homogènes). Par ailleurs, sur les zones de recouvrement, une méthode de fusion prenant en compte la distance du pixel courant avec les objets ayant servis aux différentes classifications pourra être développée.

**Réduction du nombre de classifications** Deux facteurs d'amélioration peuvent permettre de réduire le nombre de classifications. D'une part la justification de la multiplication des classifications dans MLMOL étant d'apprendre les différences d'apparences d'un thème, on pourrait adapter la stratégie d'inspection en n'inspectant que les objets n'ayant pas été classés par les classifications des objets précédents. D'autre part, l'étude des caractéristiques géométriques des objets et de leur répartition spatiale pourrait permettre de sélectionner un sous-ensemble d'objets d'un même thème potentiellement différents. Par exemple, en sélectionnant des bâtiments de petites et de grandes tailles, on peut apprendre l'apparence des maisons isolées et des bâtiments industriels ou commerciaux.

### 10.3.3 Applications envisagées

Afin de compléter ces perspectives, nous tenons à proposer différentes applications de notre chaîne de traitements auxquelles nous avons pensées durant son développement sans toutefois les mener à bien.

En continuité de l'aide à la création de BDs d'OCS issues de la fusion de différentes BDs existantes et au recettage de BDs que nous avons pu expérimenter dans le chapitre 8, notre méthode peut permettre la création d'un outil de type « OCS à la carte ». Ainsi, cet outil permettrait à un utilisateur de choisir des thèmes parmi différentes BDs existantes, et d'obtenir une BD d'OCS « sur mesure » après une étape de fusion guidée par une (ou des) image(s) satellite. Notre méthode pourrait choisir automatiquement, parmi un ensemble de données de télédétection disponibles, les données les plus pertinentes et les plus adaptées pour les thèmes choisis par l'utilisateur. Ainsi, une base de règles enrichies et définies au fur à mesure de son utilisation pourrait définir les « meilleures données » pour un thème choisi par l'utilisateur et *in fine*, indiquer si la classe indiquée par l'opérateur est détectable dans les images fournies en entrée.

Outre la capacité de mettre à jour une BD, notre méthode permet également de qualifier une BD à partir d'une image satellite. La qualification automatique de BDs géographiques ouvre la voie à différentes applications, comme la vérification de données issues de la production participative (*crowdsourcing*), ou de plate-formes destinées aux experts [Han et al., 2014]. En effet, les données produites par les utilisateurs sont un élément important pour la mise à jour des données géographiques, mais souffrent d'un certain nombre de problèmes, comme celui de la garantie de leurs qualités [Foody, 2013]. Ainsi, une image satellite pourrait venir confirmer, ou infirmer, une alerte issue d'un utilisateur.

Enfin, face à la mise à disposition croissante de données historiques, comme les archives Landsat [Wulder et al., 2012], le programme « SPOT World Heritage »<sup>1</sup> ou encore la numérisation des images aériennes anciennes de l'IGN depuis 1946, notre méthode pourrait permettre l'extraction d'informations temporelles très intéressantes, permettant une analyse sur de longues périodes de l'évolution de différents phénomènes : l'évolution de la couverture forestière, des pratiques agricoles ou de l'expansion urbaine. Notre méthode pourrait également permettre d'extraire pour chaque date l'apparence représentative de chaque thème (*e.g.*, patchs de texture). Ainsi, une base de données de ces apparences pourrait être construite et permettrait de nouvelles applications comme l'étude de l'évolution de l'apparence d'un thème ou l'utilisation de ces données pour la classification de zones non couvertes par une BD-OCS.

---

1. <http://www.cnes.fr/web/CNES-fr/6115-communicues-de-presse.php?item=8192>

# Bibliographie

---

- Abdellaoui, A., Rougab, A., 1997. Caractérisation de la réponse du bâti : application au complexe urbain de Blida (Algérie). Dans : Télédétection des milieux urbains et périurbains. Liège, Belgique, 75–83. *Cité page 32*
- Albanese, D., Visintainer, R., 2012. mlpy : machine learning Python. arXiv 1202.6548, 1–4. *Cité page 59*
- Archibald, R., Fann, G., 2007. Feature Selection and Classification of Hyperspectral Images With Support Vector Machines. IEEE Geoscience and Remote Sensing Letters 4 (4), 674–677. *Cité page 59*
- Arif, M., Hafid, S., Brouard, T., Vincent, N., 2006. AWFO (un opérateur d'agrégation) pour la reconnaissance des formes AWFO (an aggregation operator) for pattern recognition. Dans : Reconnaissance de Formes et Intelligence Artificielle. Tours, France, 31–40. *Cité page 72*
- Arvor, D., Durieux, L., Andrés, S., Laporte, M.-A., 2013. Advances in Geographic Object-Based Image Analysis with ontologies : A review of main contributions and limitations from a remote sensing perspective. ISPRS Journal of Photogrammetry and Remote Sensing 82, 125–137. *Cité page 50*
- Atkinson, P., Cutler, M., Lewis, H., 1997. Mapping sub-pixel proportional land cover with AVHRR imagery. International Journal of Remote Sensing 18 (4), 917–935. *Cité page 65*
- Baillard, C., 1997. Analyse d'images aériennes stéréo pour la restitution 3-D en milieu urbain. Thèse de Doctorat, École Nationale Supérieure des Télécommunications, Paris, France. *Cité page 41*
- Balestrat, M., 2011. Système d'indicateurs spatialisés pour la gouvernance territoriale : application à l'occupation des sols en zone périurbaine languedocienne. Thèse de Doctorat, Université Paul Valéry - Montpellier 3, France. *Cité page 4*
- Ball, G., Hall, D., 1965. ISODATA, a novel method of data analysis and pattern classification. Rapport technique, Stanford Research Institute, États-Unis. *Cité page 63*
- Banfield, R., Hall, L., 2007. A comparison of decision tree ensemble creation techniques. IEEE Pattern Analysis and Machine Intelligence 29 (1), 173–180.

- Bellman, R., 1961. Adaptive Control Processes : A Guided Tour. Princeton University Press, USA. *Cité pages 51 et 54*
- Belousov, A., Verzakov, S., Frese, J., 2002. A flexible classification approach with optimal generalisation performance : support vector machines. *Chemometrics and Intelligent Laboratory Systems* 64 (1), 15–25. *Cité pages 66 et 67*
- Belward, A., Skoien, J., 2014. Who launched what, when and why; trends in global land-cover observation capacity from civilian earth observation satellites. *ISPRS Journal of Photogrammetry and Remote Sensing* in Press. *Cité page 13*
- Benediktsson, J., Kanellopoulos, I., 1999. Classification of multisource and hyperspectral data based on decision fusion. *IEEE Transactions on Geoscience and Remote Sensing* 37 (3), 1367–1377. *Cité page 72*
- Benediktsson, J. A., Chanussot, J., Fauvel, M., 2007. Multiple Classifier Systems. Vol. 4472 de *Lecture Notes in Computer Science*. Springer Berlin Heidelberg, Berlin, Heidelberg. *Cité page 71*
- Berens, J., Finlayson, G., 2000. Log-opponent chromaticity coding of colour space. Dans : *IEEE International Conference on Pattern Recognition*. Barcelone, Espagne, 206–211. *Cité page 33*
- Beucher, S., 1992. The watershed transformation applied to image segmentation. *Scanning Microscopy International* 6, 299–314. *Cité page 50*
- Bhaskaran, S., Paramananda, S., Ramnarayan, M., 2010. Per-pixel and object-oriented classification methods for mapping urban features using Ikonos satellite data. *Applied Geography* 30 (4), 650–665. *Cité page 32*
- Bishop, C., 2006. *Pattern recognition and machine learning*. Springer, États-Unis. *Cité page 54*
- Blaschke, T., 2010. Object based image analysis for remote sensing. *ISPRS Journal of Photogrammetry and Remote Sensing* 65 (1), 2–16. *Cité page 50*
- Blaschke, T., Hay, G. J., Kelly, M., Lang, S., Hofmann, P., Addink, E., Queiroz Feitosa, R., van der Meer, F., van der Werff, H., van Coillie, F., Tiede, D., 2014. Geographic Object-Based Image Analysis - Towards a new paradigm. *ISPRS Journal of Photogrammetry and Remote Sensing* 87 (100), 180–191. *Cité page 50*
- Bosch, A., Zisserman, A., Muoz, X., 2007. Image classification using random forests and ferns. Dans : *IEEE 11th International Conference on Computer Vision*. Rio de Janeiro, Brésil, 1–8. *Cité page 69*
- Boser, B., Guyon, I., Vapnik, V., 1992. A training algorithm for optimal margin classifiers. Dans : *Proceedings of the Annual Workshop on Computational Learning Theory*. New York, États-Unis, 144–152. *Cité page 65*
- Bouffier, J., Hebrard, D., Mingam, B., Chadourne, L., Treinsoutrot, D., 2014.

- Apport de l'imagerie Pléiades pour la caractérisation de la densité urbaine. *Revue Française de Photogrammétrie et de Télédétection* 208. *Cité page 15*
- Bouziani, M., Goïta, K., He, D., 2010. Automatic change detection of buildings in urban environment from very high spatial resolution images using existing geodatabase and prior knowledge. *ISPRS Journal of Photogrammetry and Remote Sensing* 65 (1), 143–153. *Cité page 26*
- Bovolo, F., Bruzzone, L., Marchesi, S., 2009. Analysis and Adaptive Estimation of the Registration Noise Distribution in Multitemporal VHR Images. *IEEE Transactions on Geoscience and Remote Sensing* 47 (8), 2658–2671. *Cité page 22*
- Bovolo, F., Bruzzone, L., Marconcini, M., 2008. A Novel Approach to Unsupervised Change Detection Based on a Semisupervised SVM and a Similarity Measure. *IEEE Transactions on Geoscience and Remote Sensing* 46 (7), 2070–2082. *Cité page 24*
- Bradski, G., 2000. The opencv library. *Doctor Dobbs Journal*. *Cité page 75*
- Bradski, G., Kaehler, A., 2008. *Learning OpenCV : Computer vision with the OpenCV library*. O'Reilly Media, Incorporated. *Cité page 60*
- Braun, A., 2010. Evaluation of One-class SVM for Pixel-based and Segment-based Classification in Remote Sensing. *International Archives of Photogrammetry, Remote Sensing and Spatial Information Sciences* 38 (4), 160–165. *Cité page 68*
- Breiman, L., 1996a. Bagging predictors. *Machine Learning* 24 (2), 123–140. *Cité page 71*
- Breiman, L., 2001. Random forests. *Machine learning*, 1–35. *Cité pages 58, 65 et 69*
- Breiman, L., Friedman, J., Stone, C., Olshen, R., 1984. *Classification and regression trees*. CRC press, États-Unis. *Cité pages 65 et 69*
- Breiman, L. E. O., 1996b. Stacked Regressions. *Machine Learning* 24, 49–64. *Cité page 72*
- Briem, G., 2002. Multiple classifiers applied to multisource remote sensing data. *IEEE Transactions on Geoscience and Remote Sensing* 40 (10), 2291–2299. *Cité page 72*
- Bruzzone, L., Bovolo, F., 2012. A Novel Framework for the Design of Change-Detection Systems for Very-High-Resolution Remote Sensing Images. *Proceedings of the IEEE* 101 (3), 609 – 630. *Cité page 22*
- Bruzzone, L., Chi, M., Marconcini, M., 2006. A Novel Transductive SVM for Semisupervised Classification of Remote-Sensing Images. *IEEE Transactions on Geoscience and Remote Sensing* 44 (11), 3363–3373. *Cité page 64*
- Bruzzone, L., Cossu, R., Vernazza, G., 2002. Combining parametric and non-parametric algorithms for a partially unsupervised classification of multitem-

- poral remote-sensing images. *Information Fusion* 3 (4), 289–297. *Cité page 72*
- Bruzzone, L., Persello, C., 2010. Recent trends in classification of remote sensing data : active and semisupervised machine learning paradigms. Dans : *IEEE International Geoscience and Remote Sensing Symposium*. Honolulu, États-Unis, 3720–3723. *Cité page 159*
- Buck, O., 2010. DeCOVER 2 - The German GMES extension to support land cover data systems : status and outlook. Dans : *Proceedings of ESA Living Planet Symposium*. Bergen, Norvège, 37–45. *Cité page 26*
- Campedel, M., Luo, B., Maitre, H., Moulines, E., 2004. Indexation des images satellitaires : Détection et évaluation des caractéristiques de classification. Rapport technique, Télécom Paris, France. *Cité pages 57 et 59*
- Campedel, M., Moulines, E., Datcu, M., 2005. Feature selection for satellite image indexing. Dans : *ESA-EUSC : Image Information Mining*. Frascati, Italie. *Cité page 66*
- Camps-Valls, G., Bruzzone, L., 2009. Kernel methods for remote sensing data analysis. Wiley and Sons. *Cité page 65*
- Camps-Valls, G., Gomez-Chova, L., Calpe-Maravilla, J., Martin-Guerrero, J., Soria-Olivas, E., Alonso-Chorda, L., Moreno, J., 2004. Robust support vector method for hyperspectral data classification and knowledge discovery. *IEEE Transactions on Geoscience and Remote Sensing* 42 (7), 1530–1542. *Cité page 66*
- Camps-Valls, G., Gomez-Chova, L., Munoz-Mari, J., Vila-Frances, J., Calpe-Maravilla, J., 2006. Composite Kernels for Hyperspectral Image Classification. *IEEE Geoscience and Remote Sensing Letters* 3 (1), 93–97. *Cité page 159*
- Camps-Valls, G., Shervashidze, N., Borgwardt, K. M., 2010. Spatio-Spectral Remote Sensing Image Classification With Graph Kernels. *IEEE Geoscience and Remote Sensing Letters* 7 (4), 741–745. *Cité page 159*
- Camps-Valls, G., Tuia, D., Gomez-Chova, L., Jimenez, S., Malo, J., 2011. Remote sensing image processing. Morgan & Claypool Publishers. *Cité page 62*
- Cao, X., Chen, J., Matsushita, B., 2009. An automatic method for burn scar mapping using support vector machines. *International Journal of Remote Sensing* 30 (3), 577–594. *Cité page 66*
- Carr, J., de Miranda, F., 1998. The semivariogram in comparison to the co-occurrence matrix for classification of image texture. *IEEE Transactions on Geoscience and Remote Sensing* 36 (6), 1945–1952. *Cité page 39*
- Ceamanos, X., Waske, B., Benediktsson, J., Chanussot, J., Fauvel, M., Sveinsson, R., 2010. A classifier ensemble based on fusion of support vector machines for classifying hyperspectral data. *Image and Data Fusion*, 1–15. *Cité pages 71 et 72*
- Champion, N., Boldo, D., Pierrot-Deseilligny, M., Stamon, G., 2010. 2D building change detection from high resolution satellite imagery : A two-step hierar-



- chical method based on 3D invariant primitives. *Pattern Recognition Letters* 31 (10), 1138–1147. *Cité page 25*
- Chang, C., Lin, C., 2011. LIBSVM : a library for support vector machines. *ACM Transactions on Intelligent Systems and . . .* *Cité page 75*
- Chanussot, J., Mauris, G., Lambert, P., 1999. Fuzzy fusion techniques for linear features detection in multitemporal SAR images. *IEEE Transactions on Geoscience and Remote Sensing* 37 (3), 1292–1305. *Cité page 72*
- Chehata, N., Guo, L., Mallet, C., 2009. Airborne lidar feature selection for urban classification using random forests. *International Archives of Photogrammetry, Remote Sensing and Spatial Information Sciences XXXVIII (Part 3/W8)*, 207–212. *Cité pages 59 et 69*
- Chen, G., Hay, G., Carvalho, L., Wulder, A., 2012. Object-based change detection. *International Journal of Remote Sensing* 33 (14), 37–41. *Cité page 26*
- Clark, I., 1979. *Practical geostatistics*. Applied Science Publishers London, Londres, Royaume-Uni. *Cité page 39*
- Clery, I., Pierrot-Deseilligny, M., Vallet, B., 2014. Automatic georeferencing of a heritage of old analog aerial photographs. Dans : *Photogrammetric Computer Vision*. Zurich, Suisse. *Cité page 16*
- Comaniciu, D., Meer, P., 1999. Mean shift analysis and applications. Dans : *IEEE International Conference on Computer Vision*. Kerkyra, Grèce, 1197–1203. *Cité page 50*
- Coppin, P., Bauer, M., 1996. Change Detection in Forest Ecosystems with Remote Sensing Digital Imagery. *Remote sensing reviews* 13 (3-4), 207–234. *Cité page 23*
- Coppin, P., Jonckheere, I., Nackaerts, K., Muys, B., Lambin, E., 2004. Digital change detection methods in ecosystem monitoring : a review. *International Journal of Remote Sensing* 25 (9), 1565–1596. *Cité page 22*
- Corgne, S., Hubert-Moy, L., Dezert, J., Mercier, G., 2004. Land cover change prediction with a new theory of plausible and paradoxical reasoning. Dans : Smarandache, F., Dezert, J. (Eds.), *Advances and Applications of DSMT for Information Fusion*. Am. Res. Press, Rehoboth, États-Unis. *Cité page 72*
- Cortes, C., Vapnik, V., 1995. Support-vector networks. *Machine learning* 20 (3), 273–297. *Cité page 66*
- Criminisi, A., Shotton, J., 2013. *Decision forests for computer vision and medical image analysis*. Springer-Verlag, Londres, Royaume-Uni. *Cité page 69*
- Dalal, N., Triggs, B., 2005. Histograms of Oriented Gradients for Human Detection. Dans : *IEEE Computer Society Conference on Computer Vision and Pattern Recognition*. Ieee, San Diego, CA, États-Unis, 886–893. *Cité page 36*
- Dalla Mura, M., Benediktsson, J., Waske, B., Bruzzone, L., 2010. Morphological Attribute Profiles for the Analysis of Very High Resolution Images.

- IEEE Transactions on Geoscience and Remote Sensing 48 (10), 3747–3762.  
*Cité pages 48, 69, 100 et 156*
- Dalponte, M., 2008. Fusion of hyperspectral and LIDAR remote sensing data for classification of complex forest areas. IEEE Transactions on Geoscience and Remote Sensing 46 (5), 1416–1427. *Cité page 66*
- Davis, J., Goadrich, M., 2006. The Relationship Between Precision-Recall and ROC Curves. Dans : Proceedings of the 23rd International Conference on Machine learning. Pittsburgh, États-Unis, 233–240. *Cité page 73*
- Delenne, C., Durrieu, S., Rabatel, G., Deshayes, M., 2010. From pixel to vine parcel : A complete methodology for vineyard delineation and characterization using remote-sensing data. Computers and Electronics in Agriculture 70 (1), 78–83. *Cité page 42*
- Delenne, C., Rabatel, G., Agurto, V., Deshayes, M., 2006. Vine plot detection in aerial images using fourier analysis. Dans : Lang, S., Blaschke, T., Schaffer, E. (Eds.), 1st International Conference on Object-based Image Analysis. *Cité page 42*
- Demir, B., Bovolo, F., Bruzzone, L., 2013. Updating Land-Cover Maps by Classification of Image Time Series : A Novel Change-Detection-Driven Transfer Learning Approach. IEEE Transactions on Geoscience and Remote Sensing 51 (1), 300–312. *Cité page 24*
- Dempster, A., 1960. A significance test for the separation of two highly multivariate small samples. Biometrics 16 (1), 41–50. *Cité page 72*
- Derivaux, S., Forestier, G., Wemmert, C., Lefèvre, S., 2010. Supervised image segmentation using watershed transform, fuzzy classification and evolutionary computation. Pattern Recognition Letters 31 (15), 2364–2374. *Cité page 50*
- Dey, V., Zhang, Y., Zhong, M., 2010. A review on image segmentation techniques with remote sensing perspective. International Archives of Photogrammetry, Remote Sensing and Spatial Information Sciences XXXVIII (part 7A), 31–42. *Cité page 50*
- Diday, E., 1971. Une nouvelle méthode en classification automatique et reconnaissance des formes la méthode des nuées dynamiques. Revue de Statistique Appliquée 19 (2), 19–33. *Cité page 63*
- Ding, M., Tian, Z., Jin, Z., Xu, M., Cao, C., 2010. Registration Using Robust Kernel Principal Component for Object-Based Change Detection. IEEE Geoscience and Remote Sensing Letters 7 (4), 761–765. *Cité page 22*
- Domenech, E., Mallet, C., 2014. Change detection in high-resolution land use / land cover geodatabases (at object level). Rapport technique, EuroSDR n 64. *Cité page 26*
- Dunn, D., Higgins, W., 1995. Optimal Gabor filters for texture segmentation. IEEE Transactions on Image Processing 4 (7), 947–964. *Cité page 46*
- Dunn, D., Higgins, W., Wakeley, J., 1994. Texture segmentation using 2-D Gabor

- elementary functions. *IEEE Transactions on Pattern Analysis and Machine Intelligence* 16 (2), 130–149. *Cité page 46*
- Duro, D. C., Franklin, S. E., Dubé, M. G., 2012. A comparison of pixel-based and object based image analysis with selected machine learning algorithms for the classification of agricultural landscapes using SPOT 5 HRG imagery. *Remote Sensing of Environment* 118, 259–272. *Cité page 13*
- Erener, A., Düzgün, H., 2009. A methodology for land use change detection of high resolution pan images based on texture analysis. *Italian Journal of Remote Sensing* 41 (2), 47–59. *Cité page 23*
- Escalante-Ramirez, B., 2012. Remote sensing – advanced techniques and platforms. InTech. *Cité pages 62 et 69*
- Faugeras, O., 1979. Digital color image processing within the framework of a human visual model. *IEEE Transactions on Acoustics, Speech and Signal Processing* 27 (4), 380–393. *Cité page 33*
- Fauvel, M., 2013. Approximation de matrices pour l'apprentissage des hyperparamètres des fonctions noyaux Gaussiennes. Dans : *Traitement du signal et des images*. Brest, France. *Cité page 67*
- Fauvel, M., Chanussot, J., Benediktsson, J., 2006. Decision fusion for the classification of urban remote sensing images. *IEEE Transactions on Geoscience and Remote Sensing* 44 (10), 2494–2497. *Cité page 72*
- Fauvel, M., Chanussot, J., Benediktsson, J., 2012. A spatial–spectral kernel-based approach for the classification of remote-sensing images. *Pattern Recognition* 45 (1), 381–392. *Cité page 159*
- Fauvel, M., Planque, C., Sheeren, D., Dalla Mura, M., 2014. Télédétection des éléments semi-naturels : utilisation des données pléiades pour la détection des haies. *Revue Française de Photogrammétrie et de Télédétection* 208. *Cité page 15*
- Fawcett, T., 2006. An introduction to ROC analysis. *Pattern Recognition Letters* 27 (8), 861–874. *Cité pages 73 et 75*
- Fisher, R., 1936. The use of multiple measurements in taxonomic problems. *Annals of eugenics*. *Cité page 55*
- Foody, G., 1999. The significance of border training patterns in classification by a feedforward neural network using back propagation learning. *International Journal of Remote Sensing* 20 (18), 3549–3562. *Cité page 65*
- Foody, G., 2002. Status of land cover classification accuracy assessment. *Remote Sensing of Environment* 80, 185–201. *Cité page 65*
- Foody, G., 2013. Rating crowdsourced annotations : evaluating contributions of variable quality and completeness. *International Journal of Digital Earth* 7 (8), 650–670. *Cité page 162*
- Foody, G., Arora, M., 1997. An evaluation of some factors affecting the accu-

- racy of classification by an artificial neural network. *International Journal of Remote Sensing* 18 (4), 799–810. *Cité page 64*
- Foody, G., Mathur, A., 2004a. A relative evaluation of multiclass image classification by support vector machines. *IEEE Transactions on Geoscience and Remote Sensing* 42 (6), 1335–1343. *Cité pages 64 et 65*
- Foody, G., Mathur, A., 2004b. Toward intelligent training of supervised image classifications : directing training data acquisition for SVM classification. *Remote Sensing of Environment* 93 (1-2), 107–117. *Cité page 85*
- Foody, G., Mathur, A., 2006. The use of small training sets containing mixed pixels for accurate hard image classification : Training on mixed spectral responses for classification by a SVM. *Remote Sensing of Environment* 103 (2), 179–189. *Cité page 64*
- Foody, G., Mathur, A., Sanchez-Hernandez, C., Boyd, D., 2006. Training set size requirements for the classification of a specific class. *Remote Sensing of Environment* 104 (1), 1–14. *Cité page 65*
- Forestier, G., 2010. *Connaissances et clustering collaboratif d'objets complexes multisources*. Thèse de Doctorat, Université de Strasbourg, France. *Cité page 64*
- Forsyth, D., Ponce, J., 2002. *Computer vision : a modern approach*. Prentice Hall Professional Technical Reference, USA. *Cité pages 33 et 34*
- Fourier, J., 1822. *Théorie analytique de la chaleur*. Firmin Didot. *Cité pages 41 et 42*
- Freund, Y., Schapire, R., 1996. Experiments with a new boosting algorithm. Dans : *International Conference on Machine Learning*. Bari, Italie, 148–156. *Cité page 71*
- Fröhlich, B., Bach, E., 2013. Land cover classification of satellite images using contextual information. *ISPRS Annals of Photogrammetry, Remote Sensing and Spatial Information Sciences II-3 (W1)*, 1–6. *Cité page 159*
- Gao, B. C., 1996. NDWI - A normalized difference water index for remote sensing of vegetation liquid water from space. *Remote Sensing of Environment* 58, 257–266. *Cité page 32*
- Genuer, R., 2010. *Forêts aléatoires : aspects théoriques, sélection de variables et applications*. Thèse de Doctorat, Université Paris-Sud 11, France. *Cité page 69*
- Genuer, R., Poggi, J., Tuleau-Malot, C., 2010. Variable selection using random forests. *Pattern Recognition Letters* 31 (14), 2225–2236. *Cité page 69*
- Ghosh, A., Mishra, N., Ghosh, S., 2011. Fuzzy clustering algorithms for unsupervised change detection in remote sensing images. *Information Sciences* 181 (4), 699–715. *Cité pages 23 et 63*
- Gislason, P., Benediktsson, J., Sveinsson, J., 2006. Random Forests for land cover

- classification. *Pattern Recognition Letters* 27 (4), 294–300. *Cité page 69*
- Goldberg, D., 1989. *Genetic Algorithms in Search, Optimization, and Machine Learning*. Addison-Wesley Longman Publishing, États-Unis. *Cité page 57*
- Gómez-Chova, L., Muñoz Marí, J., Laparra, V., Malo-López, J., Camps-Valls, G., 2011. A Review of Kernel Methods in Remote Sensing Data Analysis. Dans : *Optical Remote Sensing*. Springer, 171–206. *Cité pages 55 et 68*
- Gould, S., Russakovsky, O., Goodfellow, I., Baumstarck, P., 2011. *STAIR Vision Library* (v2. 5). *Cité page 51*
- Green, A., Berman, M., 1988. A transformation for ordering multispectral data in terms of image quality with implications for noise removal. *IEEE Transactions on Geoscience and Remote Sensing* 26 (1), 65–74. *Cité page 54*
- Grigorescu, S., Petkov, N., Kruizinga, P., 2000. A comparative study of filter based texture operators using Mahalanobis distance. Dans : *Proceedings of the 15th International Conference on Pattern Recognition*. Barcelone, Espagne, 885–888. *Cité page 34*
- Grigorescu, S., Petkov, N., Kruizinga, P., 2002. Comparison of texture features based on Gabor filters. *IEEE Transactions on Image Processing* 11 (10), 1160–7. *Cité page 46*
- Guo, D., Atluri, V., Adam, N., 2005. Texture-based remote-sensing image segmentation. Dans : *IEEE International Conference on Multimedia and Expo*. Amsterdam, Pays-Bas, 1472–1475. *Cité page 46*
- Guyon, I., Weston, J., Barnhill, S., Vapnik, V., 2002. Gene selection for cancer classification using support vector machines. *Machine learning* 46 (1-3), 389–422. *Cité page 58*
- Han, G., Chen, J., He, C., Li, S., Wu, H., Liao, A., Peng, S., 2014. A web-based system for supporting global land cover data production. *ISPRS Journal of Photogrammetry and Remote Sensing In Pres*. *Cité page 162*
- Haralick, R., Shanmugan, K., Dinstein, I., 1973. Textural features for image classification. *IEEE Transactions on Systems, Man and Cybernetics* 3 (6), 610–621. *Cité page 36*
- Hartigan, J., Wong, M., 1979. Algorithm AS 136 : A k-means clustering algorithm. *Applied statistics* 28 (1), 100–108. *Cité page 63*
- He, Y., Khan, A., Mui, A., 2012. Integrating Remote Sensing and Wavelet Analysis for Studying Fine-scaled Vegetation Spatial Variation among Three Different Ecosystems. *Photogrammetric Engineering & Remote Sensing* 78 (2), 161 – 168. *Cité page 43*
- Hecheltjen, A., Thonfeld, F., Menz, G., 2014. Recent Advances in Remote Sensing Change Detection - A Review. Dans : *Land Use and Land Cover Mapping in Europe*. Vol. 18 de *Remote Sensing and Digital Image Processing*. Springer Pays-Bas, 145–178. *Cité page 22*

- Helmholz, P., Becker, C., Breilkopf, U., Buschenfeld, T., Busch, A., Braun, C., Grunreich, D., Muller, S., Ostermann, J., Pahl, M., Rottensteiner, F., Vogt, K., Ziems, M., Heipke, C., 2012. Semi-automatic Quality Control of Topographic Data Sets. *Photogrammetric Engineering & Remote Sensing* 78 (9), 959–972. *Cité page 25*
- Henrich, V., Jung, A., Götze, C., Sandow, C., Thürkow, D., Gläß er, C., 2009. Development of an online indices database : Motivation, concept and implementation. Dans : 6th EARSeL Imaging Spectroscopy SIG Workshop Innovative Tool for Scientific and Commercial Environment Applications. Tel Aviv, Israel, 16–18. *Cité page 32*
- Heumann, B., 2011. Satellite remote sensing of mangrove forests : Recent advances and future opportunities. *Progress in Physical Geography* 35 (1), 87–108. *Cité page 32*
- Ho, T., 1998. The random subspace method for constructing decision forests. *IEEE Transactions on Pattern Analysis and Machine Intelligence* 20 (8), 832–844. *Cité page 71*
- Hofmann, P., Lohmann, P., Müller, S., 2008. Change detection by object-based change indications. Dans : Proceedings of the 4th EARSeL Workshop on Remote Sensing for Developing Countries in Conjunction with GISDECO. Istanbul, Turquie, 4–7. *Cité page 26*
- Holland, J. H., 1975. *Adaptation in Natural and Artificial Systems*. MIT Press, Cambridge, Royaume-Uni. *Cité page 57*
- Hsu, C., Chang, C., Lin, C., 2003. A practical guide to support vector classification. Rapport technique, Department of Computer Science, National Taiwan University, Taiwan. *Cité page 67*
- Hsu, C.-W., Lin, C.-J., 2002. A comparison of methods for multiclass support vector machines. *IEEE Transactions on Neural Networks* 13 (4), 1026–7. *Cité page 68*
- Huang, C., Davis, L., Townshend, J., 2002. An assessment of support vector machines for land cover classification. *International Journal of Remote Sensing* 23 (4), 725–749. *Cité page 68*
- Huang, C., Song, K., Kim, S., Townshend, J., Davis, P., Masek, J., Goward, S., 2008. Use of a dark object concept and support vector machines to automate forest cover change analysis. *Remote Sensing of Environment* 112 (3), 970–985. *Cité page 24*
- Huang, X., Zhang, L., 2009. Road centreline extraction from high-resolution imagery based on multiscale structural features and support vector machines. *International Journal of Remote Sensing* 30 (8), 1977–1987. *Cité page 66*
- Huang, X., Zhang, L., 2013. An SVM Ensemble Approach Combining Spectral, Structural, and Semantic Features for the Classification of High-Resolution Remotely Sensed Imagery. *IEEE Transactions on Geoscience and Remote Sensing* 51 (1), 257–272. *Cité page 47*

- Huang, X., Zhang, L., Li, P., 2007. Classification and Extraction of Spatial Features in Urban Areas Using High-Resolution Multispectral Imagery. *IEEE Geoscience and Remote Sensing Letters* 4 (2), 260–264. *Cité pages 47 et 157*
- Huang, Z., Lees, B., 2004. Combining non-parametric models for multisource predictive forest mapping. *Photogrammetric Engineering & Remote Sensing* 70 (4), 415–425. *Cité page 71*
- Huete, A., 1988. A soil-adjusted vegetation index (SAVI). *Remote Sensing of Environment* 25 (3), 295–309. *Cité page 31*
- Hussain, M., Chen, D., Cheng, A., Wei, H., Stanley, D., 2013. Change detection from remotely sensed images : From pixel-based to object-based approaches. *ISPRS Journal of Photogrammetry and Remote Sensing* 80, 91–106. *Cité pages 22, 39 et 64*
- Inamdar, S., Bovolo, F., Bruzzone, L., Chaudhuri, S., 2008. Multidimensional Probability Density Function Matching for Preprocessing of Multitemporal Remote Sensing Images. *IEEE Transactions on Geoscience and Remote Sensing* 46 (4), 1243–1252. *Cité page 22*
- Indyk, P., Motwani, R., 1998. Approximate nearest neighbors : towards removing the curse of dimensionality. Dans : *Proceedings of the thirtieth annual ACM symposium on Theory of computing*. Dallas, TX, États-Unis, 604–613. *Cité page 65*
- Inglada, J., 2011. Contributions à l’analyse d’images d’observation de la Terre pour la production de cartes d’occupation des sols et le suivi des changements dans des contextes opérationnels. Habilitation à diriger des recherches, Université de Toulouse, France. *Cité page 159*
- Inglada, J., Christophe, E., 2009. The Orfeo Toolbox remote sensing image processing software. Dans : *IEEE International Geoscience and Remote Sensing Symposium*. Le Cap, Afrique du Sud, 733–736. *Cité pages 51, 59, 75 et 100*
- John, G., 1997. Enhancements to the data mining process. Thèse de Doctorat, Stanford University, États-Unis. *Cité page 58*
- Jolliffe, I., 2005. Principal component analysis. Wiley Online Library, États-Unis. *Cité page 54*
- Julea, A., Meger, N., Bolon, P., Rigotti, C., Doin, M., Lasserre, C., Trouve, E., Lazarescu, V., 2011. Unsupervised Spatiotemporal Mining of Satellite Image Time Series Using Grouped Frequent Sequential Patterns. *IEEE Transactions on Geoscience and Remote Sensing* 49 (4), 1417–1430. *Cité page 24*
- Jutten, C., Herault, J., 1991. Blind separation of sources, part I : An adaptive algorithm based on neuromimetic architecture. *Signal processing* 24 (1), 1–10. *Cité page 54*
- Kang, X., Li, S., Fang, L., Li, M., Benediktsson, J., 2015. Extended Random Walker-Based Classification of Hyperspectral Images. *IEEE Transactions on Geoscience and Remote Sensing* 53 (1), 144–153. *Cité page 159*



- Kaufman, L., Rousseeuw, P., 1987. Clustering by means of medoids. North-Holland, Pays Bas. *Cité page 63*
- Kim, H., Pang, S., Je, H., Kim, D., Bang, S., 2003. Constructing support vector machine ensemble. *Pattern Recognition* 36 (12), 2757–2767. *Cité page 71*
- Kittler, J., 1978. Feature set search algorithms. *Pattern recognition and signal processing*, 41–60. *Cité page 57*
- Kittler, J., 1998. Combining classifiers : A theoretical framework. *Pattern analysis and Applications* 1, 18–27. *Cité page 71*
- Knudby, A., LeDrew, E., Brenning, A., 2010. Predictive mapping of reef fish species richness, diversity and biomass in Zanzibar using IKONOS imagery and machine-learning techniques. *Remote Sensing of Environment* 114 (6), 1230–1241. *Cité page 66*
- Kohavi, R., John, G., 1997. Wrappers for feature subset selection. *Artificial intelligence* 97 (1), 273–324. *Cité page 58*
- Kriegler, F., Malila, W., 1969. Preprocessing transformations and their effects on multispectral recognition. Dans : *Proceedings of the Sixth International Symposium on Remote Sensing of Environment*. Ann Arbor, États-Unis, 97. *Cité page 31*
- Krogh, A., Vedelsby, J., 1995. Neural Network Ensembles, Cross Validation, and Active Learning. Dans : *Advances in Neural Information Processing Systems* 7. Morgan Kaufmann Publishers, Burlington, États-Unis. *Cité page 71*
- Kuncheva, L., Whitaker, C., 2000. Is independence good for combining classifiers? Dans : *IEEE Proceedings of the 15th International Conference on Pattern Recognition*. Barcelone, Espagne, 168–171. *Cité page 71*
- Kurtz, C., Passat, N., Gançarski, P., Puissant, A., 2010. Multi-resolution region-based clustering for urban analysis. *International Journal of Remote Sensing* 31 (22), 5941–5973. *Cité page 63*
- Kwiatkowska, E., Fargion, G., 2003. Application of machine-learning techniques toward the creation of a consistent and calibrated global chlorophyll concentration baseline dataset using remotely. *IEEE Transactions on Geoscience and Remote Sensing* 41 (12), 2844–2860. *Cité page 66*
- Ladicky, L., Russell, C., Kohli, P., Torr, P. H. S., 2010. Graph Cut based Inference with Co-occurrence Statistics. Dans : *Proceedings of the 11th European Conference on Computer Vision*. Crète, Grèce, 239–253. *Cité page 159*
- Landgrebe, D., 2005. *Signal theory methods in multispectral remote sensing*. John Wiley & Sons, New York, États-Unis. *Cité page 65*
- Larsen, R., 2002. Decomposition using maximum autocorrelation factors. *Journal of Chemometrics* 16, 427–435. *Cité page 54*
- Le Bris, A., 2012. Extraction of vineyards out of aerial ortho-image using texture information. *ISPRS Annals of Photogrammetry, Remote Sensing and Spatial*

- Information Sciences I-3, 383–388. *Cité pages 34, 39, 42 et 46*
- Le Bris, A., Chehata, N., 2011. Change detection in a topographic building database using submetric satellite images. *International Archives of Photogrammetry, Remote Sensing and Spatial Information Sciences* 38 (3), 1–6. *Cité page 25*
- Le Bris, A., Tassin, F., Chehata, N., 2013. Contribution of texture and red-edge band for vegetated areas detection and identification. Dans : 2013 IEEE International Geoscience and Remote Sensing Symposium - IGARSS. IEEE, 4102–4105. *Cité pages 41 et 138*
- Le Men, C., 2009. Segmentation Spatio-temporelle d’une séquence d’images satellitaires à haute résolution. Thèse de Doctorat, Ecole Nationale Supérieure des Télécommunications, Paris, France. *Cité page 24*
- Lebart, L., Morineau, A., Piron, M., 1997. Statistique exploratoire multidimensionnelle. Dunod, Paris, France. *Cité page 55*
- Leblanc, M., Tibshirani, R., 1996. Combining Estimates in Regression and Classification. *Journal of the American Statistical Association* 91 (436), 1641–1650. *Cité page 72*
- Lee, J., Woodyatt, A., Berman, M., 1990. Enhancement of high spectral resolution remote-sensing data by a noise-adjusted principal components transform. *IEEE Transactions on Geoscience and Remote Sensing* 28 (3), 295–304. *Cité page 54*
- Lefebvre, A., 2011. 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 Doctorat, Université Rennes 2, France. *Cité page 34*
- Lefebvre, A., Corpetti, T., Hubert-Moy, L., 2008. Object-oriented approach and texture analysis for change detection in very high resolution images. Dans : IEEE International Geoscience and Remote Sensing Symposium. Boston, États-Unis, 663–666. *Cité pages 34 et 50*
- Lefèvre, S., Courtrai, L., 2014. Road Network Extraction from Remote Sensing using Region-based Mathematical Morphology. Dans : International Workshop on Pattern Recognition in Remote Sensing. Stockholm, Suède. *Cité page 25*
- Lefèvre, S., Weber, J., Sheeren, D., 2007. Automatic Building Extraction in VHR Images Using Advanced Morphological Operators. Dans : IEEE Urban Remote Sensing Joint Event. Paris, France. *Cité page 47*
- Levi, K., Weiss, Y., 2004. Learning object detection from a small number of examples : the importance of good features. Dans : Proceedings of the Computer Society Conference on Computer Vision and Pattern Recognition. Vol. 2. Washington, États-Unis, 53–60. *Cité page 36*
- Lienou, M., 2009. Apprentissage automatique des classes d’occupation du sol et représentation en mots visuels des images satellitaires. Thèse de Doctorat, Télécom ParisTech, France. *Cité pages 42, 50 et 64*

- Lin, H., Lin, C., Weng, R., 2007. A note on Platt's probabilistic outputs for support vector machines. *Machine Learning* 68 (3), 267–276. *Cité page 68*
- Liu, H., Setiono, R., 1996. Feature Selection and Classification : A Probabilistic Wrapper Approach. Dans : *Proceedings of the 9th International Conference on Industrial and Engineering Applications of Artificial Intelligence and Expert Systems*. Fukuoka, Japon, 419–424. *Cité page 57*
- Liu, W., Gopal, S., Woodcock, C., 2004. Uncertainty and confidence in land cover classification using a hybrid classifier approach. *Photogrammetric Engineering & Remote Sensing* 70 (8), 963–972. *Cité pages 71 et 72*
- Lohmann, P., Hofmann, P., Müller, S., 2008. Updating GIS by object-based change detection. Dans : Schiewe, J., Michel, U. (Eds.), *Geoinformatics paves the Highway to Digital Earth*. 81–86. *Cité page 26*
- Loncaric, S., 1998. A survey of shape analysis techniques. *Pattern Recognition* 31 (8), 983–1001. *Cité page 50*
- Longbotham, N., Pacifici, F., Kuester, M., 2014. Superspectral land-cover classification at very-high spatial resolution with Worldview-3 simulated data. Dans : *IEEE International Geoscience and Remote Sensing Symposium*. Québec, Canada. *Cité pages 13 et 69*
- Louis, W., Plataniotis, K., 2011. Co-Occurrence of Local Binary Patterns Features for Frontal Face Detection in Surveillance Applications. *EURASIP Journal on Image and Video Processing* 2011 (1), 1–17. *Cité pages 34 et 46*
- Löw, F., Michel, U., Dech, S., Conrad, C., 2013. Impact of feature selection on the accuracy and spatial uncertainty of per-field crop classification using Support Vector Machines. *ISPRS Journal of Photogrammetry and Remote Sensing* 85, 102–119. *Cité page 69*
- Lowe, D. G., 2004. Distinctive Image Features from Scale-Invariant Keypoints. *International Journal of Computer Vision* 60 (2), 91–110. *Cité page 46*
- Lowitz, G. E., 1983. Can a local histogram really map texture information? *Pattern Recognition* 16 (2), 141–147. *Cité page 36*
- Lu, D., Li, G., Moran, E., 2014. Current situation and needs of change detection techniques. *International Journal of Image and Data Fusion* 5 (1), 13–38. *Cité page 22*
- Lu, D., Weng, Q., 2007. A survey of image classification methods and techniques for improving classification performance. *International Journal of Remote Sensing* 28 (5), 823–870. *Cité pages 65 et 71*
- Lv, Z., Zhang, P., Benediktsson, J., Shi, W., 2014. Morphological Profiles Based on Differently Shaped Structuring Elements for Classification of Images With Very High Spatial Resolution. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 1–9. *Cité page 49*
- MacQueen, J., 1967. Some methods of classification and analysis of multivariate observations. Dans : *the Fifth Berkeley Symposium on Mathematical Statistics*

- and Probability. Berkeley, États-Unis, 281–297. *Cité page 63*
- Malisiewicz, T., Gupta, A., Efros, A., 2011. Ensemble of Exemplar-SVMs for Object Detection and Beyond. Dans : IEEE International Conference on Computer Vision. Barcelone, Espagne, 89–96. *Cité pages 71, 72 et 84*
- Mallat, S., 1989. A theory for multiresolution signal decomposition : the wavelet representation. IEEE Transactions on Pattern Analysis and Machine Intelligence 11 (7), 674–693. *Cité page 41*
- Mantero, P., Moser, G., Serpico, S., 2005. Partially supervised classification of remote sensing images through SVM-based probability density estimation. IEEE Transactions on Geoscience and Remote Sensing 43 (3), 559–570. *Cité page 66*
- Marçal, A., Borges, J., Gomes, J., Pinto Da Costa, J., 2005. Land cover update by supervised classification of segmented ASTER images. International Journal of Remote Sensing 26 (7), 1347–1362. *Cité page 26*
- Marill, T., Green, D., 1963. On the effectiveness of receptors in recognition systems. IEEE Transactions on Information Theory 9 (1), 11–17. *Cité page 57*
- Mather, P., Koch, M., 2010. Computer processing of remotely-sensed images : an introduction. John Wiley and Sons, Hoboken, États-Unis. *Cité page 64*
- Melgani, F., Bruzzone, L., 2004. Classification of hyperspectral remote sensing images with support vector machines. IEEE Transactions on Geoscience and Remote Sensing 42 (8), 1778–1790. *Cité pages 66 et 68*
- Mercier, G., Lennon, M., 2003. Support vector machines for hyperspectral image classification with spectral-based kernels. Dans : IEEE International Geoscience and Remote Sensing Symposium. Toulouse, France, 288–290. *Cité page 68*
- Mercier, G., Tupin, F., 2014. Analyse de séries multi-temporelles et détection de changements. Dans : Imagerie de télédétection. Hermes - Lavoisier, Paris, France, 223–239. *Cité pages 22 et 24*
- Merz, C., 1999. Using Correspondence Analysis to Combine Classifiers. Machine Learning 36 (1-2), 33–58. *Cité page 72*
- Merz, C., Pazzani, M., 1999. A principal components approach to combining regression estimates. Machine Learning 36 (1-2), 9–32. *Cité page 72*
- Messick, S., Abelson, R., 1956. The additive constant problem in multidimensional scaling. Psychometrika 21 (1), 1–15. *Cité page 55*
- Metz, C., 1978. Basic principles of ROC analysis. Seminars in nuclear medicine. *Cité pages 73 et 75*
- Mika, S., Smola, A., Schölkopf, B., 2001. An improved training algorithm for kernel fisher discriminants. Dans : Proceedings AISTATS. Key West, États-Unis, 98–104. *Cité page 55*

- Miller, A., Bryant, E., Birnie, R., 1998. An analysis of land cover changes in the Northern Forest of New England using multitemporal Landsat MSS data. *International Journal of Remote Sensing* 19 (2), 245–265. *Cité page 23*
- Mojirsheibani, M., 1999. Combining Classifiers via Discretization. *Journal of the American Statistical Association* 94 (446), 600–609. *Cité page 72*
- Mole, S., Ganesan, L., 2010. Unsupervised Hybrid Classification for Texture Analysis Using Fixed and Optimal Window Size. *International Journal on Computer Science & Engineering* 02 (09), 2910–2915. *Cité page 39*
- Montoya-Zegarra, J., Wegner, J., Ladicky, L., Schindler, K., 2014. Mind the gap : modeling local and global context in (road) networks. Dans : *German Conference on Pattern Recognition*. Münster, Allemagne. *Cité page 159*
- Mountrakis, G., Im, J., Ogole, C., 2011. Support vector machines in remote sensing : A review. *ISPRS Journal of Photogrammetry and Remote Sensing* 66 (3), 247–259. *Cité page 66*
- Muñoz Marí, J., 2010. Semisupervised one-class support vector machines for classification of remote sensing data. *IEEE Transactions on Geoscience and Remote Sensing* 48 (8), 3188–3197. *Cité pages 68 et 159*
- Mulcahy, C., 1997. Image compression using the Haar wavelet transform. *Spelman Science and Mathematics Journal* 1 (1), 22–31. *Cité page 44*
- Narendra, P., Fukunaga, K., 1977. A branch and bound algorithm for feature subset selection. *IEEE Transactions on Computers* 26 (9), 917–922. *Cité page 57*
- Otsu, N., 1979. A threshold selection method from gray-level histograms. *IEEE Transactions on Systems, Man and Cybernetics* 9 (1), 62–66. *Cité page 50*
- Pacifici, F., Longbotham, N., Baugh, B., 2014. Introduction to the Worldview-3 very-high spatial-resolution super-spectral bands. Dans : *IEEE International Geoscience and Remote Sensing Symposium*. Québec, Canada. *Cité page 13*
- Pal, M., 2005. Random forest classifier for remote sensing classification. *International Journal of Remote Sensing* 26 (1), 217–222. *Cité pages 24 et 69*
- Pal, N., Pal, S., 1993. A review on image segmentation techniques. *Pattern recognition* 26 (9), 1277–1294. *Cité page 50*
- Paola, J., Schowengerdt, R., 1995. A review and analysis of backpropagation neural networks for classification of remotely-sensed multi-spectral imagery. *International Journal of Remote Sensing* 16, 3033–3058. *Cité page 65*
- Pausader, M., Cantou, J., Tinel, C., Fontannaz, D., 2013. Potential of Pleiades VHR data for mapping applications. Dans : *IEEE International Geoscience and Remote Sensing Symposium*. Melbourne, Australie, 4313–4316. *Cité page 15*
- Pearson, R., Miller, L., Tucker, C., 1976. Hand-held spectral radiometer to estimate gramineous biomass. *Applied Optics* 15 (2), 416–8. *Cité page 31*

- Pesaresi, M., Benediktsson, J., 2001. A new approach for the morphological segmentation of high-resolution satellite imagery. *IEEE Transactions on Geoscience and Remote Sensing* 39 (2), 309–320. *Cité page 48*
- Pesaresi, M., Gerhardinger, A., Kayitakire, F., 2008. A Robust Built-Up Area Presence Index by Anisotropic Rotation-Invariant Textural Measure. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing* 1 (3), 180–192. *Cité page 39*
- Petitjean, F., Gañçarski, P., Masegla, F., Forestier, G., 2010. Analysing satellite image time series by means of pattern mining. Dans : *Intelligent Data Engineering and Automated Learning*. Paisley, Royaume-Uni, 45–52. *Cité page 24*
- Petitjean, F., Inglada, J., Gañçarski, P., 2012. Satellite Image Time Series Analysis Under Time Warping. *IEEE Transactions on Geoscience and Remote Sensing* 50 (8), 3081–3095. *Cité page 25*
- Pieczonka, T., Bolch, T., Junfeng, W., Shiyin, L., 2013. Heterogeneous mass loss of glaciers in the Aksu-Tarim Catchment (Central Tien Shan) revealed by 1976 KH-9 Hexagon and 2009 SPOT-5 stereo imagery. *Remote Sensing of Environment* 130, 233–244. *Cité page 13*
- Piper, J., 1992. Variability and bias in experimentally measured classifier error rates. *Pattern Recognition Letters* 13 (10), 685–692. *Cité page 64*
- Platt, J., 1999. Probabilistic Outputs for Support Vector Machines and Comparisons to Regularized Likelihood Methods. Dans : *Advances in large margin classifiers*. Cambridge, États-Unis. *Cité page 68*
- Pontius, R. G., Millones, M., 2011. Death to Kappa : birth of quantity disagreement and allocation disagreement for accuracy assessment. *International Journal of Remote Sensing* 32 (15), 4407–4429. *Cité page 73*
- Poulain, V., 2010. Fusion d’images optique et radar à haute résolution pour la mise à jour de bases de données cartographiques. Thèse de Doctorat, Université de Toulouse, France. *Cité page 25*
- Pudil, P., Novovičová, J., Kittler, J., 1994. Floating search methods in feature selection. *Pattern Recognition Letters* 15 (11), 1119–1125. *Cité page 57*
- Puissant, A., 2003. Information Géographique et Images à Très Haute Résolution Utilité et Applications en Milieu Urbain. Thèse de Doctorat, Université Strasbourg 1, France. *Cité page 39*
- Quarmby, N., Cushnie, J., 1989. Monitoring urban land cover changes at the urban fringe from SPOT HRV imagery in south-east England. *International Journal of Remote Sensing* 10 (6), 953–963. *Cité page 23*
- Radoux, J., 2010. Updating land cover maps by GIS-driven analysis of very high spatial resolution satellite images. Thèse de Doctorat, Université catholique de Louvain, Belgique. *Cité page 26*
- Ranchin, T., Wald, L., 1993. The wavelet transform for the analysis of remotely sensed images. *International Journal of Remote Sensing* 14 (3), 615–619.

*Cité page 43*

Reis, S., Taşdemir, K., 2011. Identification of hazelnut fields using spectral and Gabor textural features. *ISPRS Journal of Photogrammetry and Remote Sensing* 66 (5), 652–661. *Cité page 46*

Richardson, A., Weigand, C., 1977. Distinguishing vegetation from soil background information. *Photogrammetric Engineering & Remote Sensing* 43 (12). *Cité page 31*

Rogan, J., Chen, D., 2004. Remote sensing technology for mapping and monitoring land-cover and land-use change. *Progress in Planning* 61 (4), 301–325. *Cité page 13*

Roli, F., Giacinto, G., Vernazza, G., 2001. Methods for designing multiple classifier systems. Dans : *Proceedings of the second international workshop on multiple classifier systems*. Cambridge, Royaume-Uni, 78–87. *Cité page 71*

Rondeaux, G., Steven, M., Baret, F., 1996. Optimization of soil-adjusted vegetation indices. *Remote Sensing of Environment* 55 (2), 95–107. *Cité page 32*

Rouse, J., 1974. Monitoring the vernal advancement and retrogradation (green-wave effect) of natural vegetation. *Rapport technique*, College Station : Texas A & M University, États-Unis. *Cité page 31*

Sabu, A., Ponraj, N., 2012. Textural Features Based Breast Cancer Detection : A Survey. *Journal of Emerging Trends in Computing and Information Sciences* 3 (9), 1329–1334. *Cité pages 34, 39 et 46*

Salehi, B., Zhang, Y., Zhong, M., 2011. Combination of object-based and pixel-based image analysis for classification of vhr imagery over urban areas. Dans : *Proceedings of the annual Conference the American Society for Photogrammetry and Remote Sensing*. Milwaukee, États-Unis. *Cité page 32*

Santner, J., Pock, T., Bischof, H., 2010. Interactive multi-label segmentation. Dans : *Proceedings of the 10th Asian conference on Computer Vision*. Queenstown, Nouvelle-Zélande, 397–410. *Cité page 33*

Schölkopf, B., Smola, A., 2002. *Learning with kernels*. MIT press, Cambridge, États-Unis. *Cité pages 55 et 65*

Schölkopf, B., Smola, A., Müller, K., 1998. Nonlinear component analysis as a kernel eigenvalue problem. *Neural computation* 10 (5), 1299–1319. *Cité page 55*

Sesnie, S., Gessler, P., Finegan, B., Thessler, S., 2008. Integrating Landsat TM and SRTM-DEM derived variables with decision trees for habitat classification and change detection in complex neotropical environments. *Remote Sensing of Environment* 112 (5), 2145–2159. *Cité page 24*

Settles, B., 2010. *Active learning literature survey*. Rapport technique, University of Wisconsin, Madison, États-Unis. *Cité page 160*

Shafer, G., 1976. *A mathematical theory of evidence*. Princeton university press



- Princeton, États-Unis. *Cité page 72*
- Silleos, N., Alexandridis, T., Gitas, I., Perakis, K., 2006. Vegetation indices : advances made in biomass estimation and vegetation monitoring in the last 30 years. *Geocarto International* 21 (4), 21–28. *Cité page 32*
- Singh, A., Tiwari, S., Shukla, V., 2012. Wavelet based multi class image classification using neural network. *International Journal of Computer Applications* 37 (4), 21–25. *Cité page 44*
- Singh, M., Singh, S., 2002. Spatial texture analysis : a comparative study. Dans : *Proceedings of the 16th international conference on Pattern Recognition*. Québec, Canada, 676–679. *Cité page 34*
- Smarandache, F., 1991. Only problems, not solutions! *Infinite Study*. *Cité page 72*
- Smarandache, F., Dezert, J., 2004. Advances and applications of DSMT for information fusion. Vol. 1. American Research Press, Rehoboth, États-Unis. *Cité page 159*
- Smarandache, F., Dezert, J., 2006. Advances and Applications of DSMT for Information Fusion (Collected works), second volume : Collected Works. *Infinite Study*. *Cité page 72*
- Smith, A., 2010. Image segmentation scale parameter optimization and land cover classification using the Random Forest algorithm. *Journal of Spatial Science* 55 (1), 69–79. *Cité page 24*
- Smits, P., 2002. Multiple classifier systems for supervised remote sensing image classification based on dynamic classifier selection. *IEEE Transactions on Geoscience and Remote Sensing* 40 (4), 801–813. *Cité page 72*
- Somol, P., Vácha, P., Mikeš, S., Hora, J., Pudil, P., Žid, P., 2010. Introduction to Feature Selection Toolbox 3 – The C++ Library for Subset Search, Data Modeling and Classification. UTIA TR No. 2287, Czech Academy of Sciences. *Cité page 59*
- Song, M., Civco, D., 2004. Road extraction using SVM and image segmentation. *Photogrammetric Engineering & Remote Sensing* 70 (12), 1365–1371. *Cité page 66*
- Sonka, M., Hlavac, V., Boyle, R., 2014. *Image Processing, Analysis, and Machine Vision*. Cengage Learning, Stamford, États-Unis. *Cité page 50*
- Souza, C., 2003. Mapping forest degradation in the Eastern Amazon from SPOT 4 through spectral mixture models. *Remote Sensing of Environment* 87 (4), 494–506. *Cité page 12*
- Steele, B., 2000. Combining Multiple Classifiers : An Application Using Spatial and Remotely Sensed Information for Land Cover Type Mapping. *Remote Sensing of Environment* 74 (3), 545–556. *Cité pages 71 et 72*
- Strobl, C., Boulesteix, A., Zeileis, A., Hothorn, T., 2007. Bias in random forest

- variable importance measures : illustrations, sources and a solution. *BMC Bioinformatics* 8, 25. *Cité page 69*
- Takamura, S., Kobayashi, N., 2002. Practical extension to CIELUV color space to improve uniformity. Dans : *Proceedings of the International Conference on Image Processing*. New York, États-Unis, 393–396. *Cité page 33*
- Talukder, K., Harada, K., 2010. Haar Wavelet Based Approach for Image Compression and Quality Assessment of Compressed Image. *IAENG International Journal of Applied Mathematics* 36 (1), 8. *Cité page 44*
- Tenenbaum, J. B., de Silva, V., Langford, J. C., 2000. A global geometric framework for nonlinear dimensionality reduction. *Science* 290 (5500), 2319–23. *Cité page 56*
- Thibault, G., Fertil, B., Navarro, C., Pereira, S., 2009. Texture Indexes and Gray Level Size Zone Matrix Application to Cell Nuclei Classification. *Pattern Recognition and Information Processing*, 140–145. *Cité page 39*
- Thomas, J., Bowyer, K., Kareem, A., 2012. Color balancing for change detection in multitemporal images. Dans : *IEEE Workshop on Applications of Computer Vision*. Ieee, Breckenridge, États-Unis, 385–390. *Cité page 22*
- Tinel, C., 2014. Numéro Spécial Pléiades. *Revue Française de Photogrammétrie et de Télédétection* 208. *Cité page 15*
- Tokarczyk, P., Wegner, J., Walk, S., Schindler, K., 2015. Features, Color Spaces, and Boosting : New Insights on Semantic Classification of Remote Sensing Images. *IEEE Transactions on Geoscience and Remote Sensing* 53 (1), 280–295. *Cité page 33*
- Trias-Sanz, R., 2006a. Semi-automatic Rural Land Cover Classification from High Resolution Remote Sensing Images. Thèse de Doctorat, Université Paris 5, France. *Cité pages 16, 41 et 46*
- Trias-Sanz, R., 2006b. Texture Orientation and Period Estimator for Discriminating Between Forests, Orchards, Vineyards, and Tilled Fields. *IEEE Transactions on Geoscience and Remote Sensing* 44 (10), 2755–2760. *Cité pages 33 et 34*
- Trias-Sanz, R., Boldo, D., 2005. A High-Reliability, High-Resolution Method for Land Cover Classification Into Forest and Non-forest. Dans : *Proceedings of the 14th Scandinavian conference on Image Analysis*. Vol. 3540 de *Lecture Notes in Computer Science*. Springer, Joensuu, Finlande, 831–840. *Cité page 65*
- Trias-Sanz, R., Stamon, G., Louchet, J., 2008. Using colour, texture, and hierarchical segmentation for high-resolution remote sensing. *ISPRS Journal of Photogrammetry and Remote Sensing* 63 (2), 156–168. *Cité page 100*
- Tso, B., Mather, P., 2009. *Classification Methods for Remotely Sensed Data*, Second Edition. CRC Press, Boca Raton, États-Unis. *Cité page 65*
- Tuia, D., Muñoz Marí, J., 2011. Structured output SVM for remote sensing image

- classification. Dans : IEEE International Workshop on Machine Learning for Signal Processing. Pékin, Chine. *Cité page 159*
- Tuia, D., Munoz-Mari, J., 2013. Learning User's Confidence for Active Learning. IEEE Transactions on Geoscience and Remote Sensing 51 (2), 872–880. *Cité page 160*
- Tuia, D., Volpi, M., Copa, L., 2011. A survey of active learning algorithms for supervised remote sensing image classification. IEEE Journal of Selected Topics in Signal Processing 5 (3), 606–617. *Cité page 159*
- Tupin, F., Bloch, I., Maitre, H., 1999. A first step toward automatic interpretation of SAR images using evidential fusion of several structure detectors. IEEE Transactions on Geoscience and Remote Sensing 37 (3), 1327–1343. *Cité page 72*
- Tupin, F., Inglada, J., Mercier, G., 2014a. Techniques de traitement d'image pour la télédétection. Dans : Imagerie de télédétection. Hermès - Lavoisier, Paris, France, Ch. 5, 145–174. *Cité pages 71 et 72*
- Tupin, F., Maitre, H., Mangin, J.-F., Nicolas, J.-M., Pechersky, E., 1998. Detection of linear features in SAR images : application to road network extraction. IEEE Transactions on Geoscience and Remote Sensing 36 (2), 434–453. *Cité page 25*
- Tupin, F., Nicolas, J., Inglada, J., 2014b. Imagerie de télédétection. Hermès - Lavoisier, Paris, France. *Cité page 62*
- Vakili, V., Veksler, O., 2010. Object class segmentation using reliable regions. Dans : Proceedings of the Asian Conference on Computer Vision. Queenstown, Nouvelle-Zélande, 123–136. *Cité pages 36 et 50*
- van de Sande, K., Gevers, T., Snoek, C., 2010. Evaluating color descriptors for object and scene recognition. IEEE Transactions on Pattern Analysis and Machine Intelligence 32 (9), 1582–96. *Cité pages 36, 51, 100 et 157*
- Van Niel, T., Mvcar, T., Datt, B., 2005. On the relationship between training sample size and data dimensionality : Monte Carlo analysis of broadband multi-temporal classification. Remote Sensing of Environment 98 (4), 468–480. *Cité page 64*
- Vandenbroucke, N., Macaire, L., Postaire, J., 2003. Color image segmentation by pixel classification in an adapted hybrid color space. Application to soccer image analysis. Computer Vision and Image Understanding 90 (2), 190–216. *Cité page 34*
- Vapnik, V., 1998. Statistical learning theory. Wiley, Hoboken, États-Unis. *Cité page 66*
- Vaudour, E., Noirot-Cosson, P., Membrive, O., 2014. Apport des images satellitaires de très haute résolution spatiale pleiades à la caractérisation des cultures et des opérations culturelles en début de saison. Revue Française de Photogrammétrie et de Télédétection 208. *Cité page 15*

- Vedaldi, A., Fulkerson, B., 2010. VLFeat : An open and portable library of computer vision algorithms. Dans : Proceedings of the International Conference on Multimedia. Florence, Italie, 1469–1472. *Cité page 51*
- Velloso, M., de Souza, F., Simoes, M., 2002. Improved radiometric normalization for land cover change detection : an automated relative correction with artificial neural network. Dans : IEEE International Geoscience and Remote Sensing Symposium. Toronto, Canada, 3435–3437. *Cité page 22*
- Vertan, C., Boujemaa, N., 2000. Color texture classification by normalized color space representation. Dans : Proceedings of the 15th International Conference on Pattern Recognition. Barcelone, Espagne, 580–583. *Cité page 33*
- Volpi, M., 2013. Kernel-based methods for change detection in remote sensing images. Thèse de Doctorat, University of Lausanne, Suisse. *Cité page 23*
- Walker, J., 1996. Fast Fourier transforms. CRC press, Boca Raton, États-Unis. *Cité page 42*
- Walter, V., 2004. Object-based classification of remote sensing data for change detection. ISPRS Journal of Photogrammetry and Remote Sensing 58 (3-4), 225–238. *Cité pages 26 et 50*
- Warrender, C., Augusteijn, M., 1999. Fusion of image classifications using Bayesian techniques with Markov random fields. International Journal of Remote Sensing 20, 1987–2002. *Cité page 71*
- Waske, B., Benediktsson, J., 2007. Fusion of support vector machines for classification of multisensor data. IEEE Transactions on Geoscience and Remote Sensing 45 (12), 3858–3866. *Cité pages 72 et 87*
- Wemmert, C., Puissant, A., Forestier, G., Gançarski, P., 2009. Multiresolution Remote Sensing Image Clustering. IEEE Geoscience and Remote Sensing Letters 6 (3), 533–537. *Cité page 63*
- Weston, J., Elisseeff, A., 2003. Use of the zero norm with linear models and kernel methods. The Journal of Machine Learning Research 3. *Cité page 58*
- Whitney, A., 1971. A Direct Method of Nonparametric Measurement Selection. IEEE Transactions on Computers 20 (9), 1100–1103. *Cité page 57*
- Wilson, E., Sader, S., 2002. Detection of forest harvest type using multiple dates of Landsat TM imagery. Remote Sensing of Environment 80 (3), 385–396. *Cité page 23*
- Wolpert, D., 1992. Stacked generalization. Neural Networks 5, 241–259. *Cité page 72*
- Wolter, P. T., Townsend, P. A., Sturtevant, B. R., 2009. Estimation of forest structural parameters using 5 and 10 meter SPOT 5 satellite data. Remote Sensing of Environment 113 (9), 2019–2036. *Cité page 13*
- Wu, T., Lin, C., Weng, R., 2004. Probability estimates for multi-class classification by pairwise coupling. The Journal of Machine Learning Research 5,

975–1005.

*Cité page 68*

Wulder, M. A., Masek, J. G., Cohen, W. B., Loveland, T. R., Woodcock, C. E., 2012. Opening the archive : How free data has enabled the science and monitoring promise of Landsat. *Remote Sensing of Environment* 122, 2–10.

*Cité page 162*

Zarco-Tejada, P., Ustin, S., 2001. Modeling canopy water content for carbon estimates from MODIS data at Land EOS validation sites. Dans : *IEEE International Geoscience and Remote Sensing Symposium*. Sydney, Australie, 342–344.

*Cité page 32*

Zhang, D., Lu, G., 2004. Review of shape representation and description techniques. *Pattern Recognition* 37 (1), 1–19.

*Cité page 50*

Zhang, J., 2010. Multi-source remote sensing data fusion : status and trends. *International Journal of Image and Data Fusion* 1 (1), 5–24.

*Cité pages 71 et 159*

Zhang, L., Huang, X., Huang, B., Li, P., 2006. A pixel shape index coupled with spectral information for classification of high spatial resolution remotely sensed imagery. *IEEE Transactions on Geoscience and Remote Sensing* 44 (10), 2950–2961.

*Cité page 47*

Zhang, W., Sun, X., Fu, K., Wang, C., Wang, H., 2014. Object Detection in High-Resolution Remote Sensing Images Using Rotation Invariant Parts Based Model. *IEEE Geoscience and Remote Sensing Letters* 11 (1), 74–78. *Cité page 36*

Zhou, W., Troy, A., Grove, M., 2008. Object-based land cover classification and change analysis in the Baltimore metropolitan area using multitemporal high resolution remote sensing data. *Sensors* 8 (3), 1613–1636.

*Cité page 50*

Zhu, C., Yang, X., 1998. Study of remote sensing image texture analysis and classification using wavelet. *International Journal of Remote Sensing* 19 (16), 3197–3203.

*Cité page 43*

Zhu, G., Blumberg, D., 2002. Classification using ASTER data and SVM algorithms : The case study of Beer Sheva, Israel. *Remote Sensing of Environment* 80 (2), 233–240.

*Cité page 68*

Zhuang, X., Engel, B., Lozano-Garcia, D., Fernandez, R., Johannsen, C., 1994. Optimization of training data required for neuro-classification. *International Journal of Remote Sensing* 15 (16), 3271–3277.

*Cité page 64*

Ziems, M., Breitkopf, U., Heipke, C., Rottensteiner, F., 2012. Multiple-model based verification of road data. *ISPRS Annals of Photogrammetry, Remote Sensing and Spatial Information Sciences* I-3, 329–334.

*Cité page 25*



# Listes des termes

---

- LPN** Land-cover databases Updating by Processing Images in Natural environment. iii, iv, xiii, 17, 18, 80, 81, 98, 99, 104, 109–112, 120, 131, 136, 138, 143, 156–158, 160
- ACP** Analyse en Composantes Principales. 24, 46, 54–56
- ALD** Analyse Linéaire Discriminante. 55
- AWFO** Aggregation Weight-Functional Operators. xvii, 72, 104, 106, 107, 121, 123
- BD** base de données. iii, iv, xiv, xv, xvii, 5–12, 16, 17, 22, 24–27, 30, 51, 64, 71, 75, 80–92, 94, 95, 98, 100, 102, 103, 106, 108–110, 112, 116, 118–122, 124, 129, 131, 134–136, 138, 148, 150, 156–162
- BD-Alt**i base de données Altimétrique de l'IGN. 7
- BD-Forêt** base de données Forêts (végétation) de l'IGN. 10, 120
- BD-Ortho** base de données Ortho-photographique de l'IGN. 7
- BD-Unie** base de données Unifiée (topographique) de l'IGN. 10
- Car Hab** Cartographie des habitats et végétations de France. 8
- CEREMA** Centre d'Étude et d'Expertise sur les Risques, l'Environnement, la Mobilité et l'Aménagement. 10
- CIE** Commission Internationale de l'Éclairage. 33
- CLC** Corine Land Cover. iii, 4, 6–8, 10, 11, 26, 116, 120
- CNES** Centre National d'Études Spatiales. 12, 13, 51
- CRIGE** Centre Régionale de l'Information Géographique. 7
- DGALN** Direction générale de l'Aménagement du Logement et de la Nature, dépendant du Ministère de l'Écologie, du Développement Durable et de l'Énergie. 10
- DTW** Dynamic Time Warping. 25
- EEA** Agence Environnementale Européenne. 5, 6



- FA** Forêts Aléatoires. xiv, 24, 58–60, 62, 64–66, 69, 71, 72, 75, 100, 102–105, 109–111, 120, 121, 140
- GLCM** Grey-Level Co-occurrence Matrix. 36
- GMES** Global Monitoring for Environnement and Security. 5, 26
- HELM** Harmonised European Land Monitoring. 6
- HR** haute résolution. 46, 59
- ICA** Analyse en Composantes Indépendantes. 54, 56
- IGN** Institut National de l’Information Géographique et Forestière. iii, iv, 4–6, 9–11, 112, 138, 157, 160, 162, 197
- INSPIRE** Infrastructure for Spatial Information in the European Community. 6, 7
- IRSTEA** Institut National de Recherche en Sciences et Technologies pour l’Environnement et l’Agriculture. 9
- MAF** Maximum Autocorrelation Factor. 54, 56
- MLMOL** Multi Level, Multi Object Learning. iii, xiv, 17, 18, 80, 81, 84, 85, 89, 90, 92, 93, 95, 98–100, 103, 106, 110, 156–158, 160, 161
- MNS** Modèle Numérique de Surface. 25, 158
- MOS** Mode d’Occupation du Sol. 8, 11
- NDVI** Normalized Difference Vegetation Index. 31–33
- nomenclature** Une nomenclature désigne une instance de classification (code, tableau, liste, règles d’attribution d’identité...) faisant autorité et servant de référence à une discipline donnée (exemples : la chimie, les sciences de la vie, l’astronomie, *etc.*). (Wikipédia). Dans ce document, il s’agit de l’ensemble des classes d’occupations du sol représentées et répertoriées dans une base de donnée. . 4–10, 16, 80
- OCS** occupation du sol. iii, iv, xiv, xvii, 4, 5, 7–11, 13, 16, 17, 24, 26, 27, 51, 64, 80, 95, 98, 102, 106, 108, 110, 116, 118, 129, 136, 138, 150, 156, 157, 162
- OCS-GE** occupation du sol à grande échelle. iii, iv, xv, xvii, 10, 11, 16, 18, 112, 116, 118, 120, 121, 131, 134, 138, 156–158
- OTB** Orfeo Toolbox. 51, 60, 75
- OTOS** Observation de la Terre Optique Super Résolue. 13
- PA** profil d’attributs. 48, 49, 108
- PIR** proche infra-rouge. 31
- PLU** Plan Local d’Urbanisme. 4

**PM** profil morphologique. 48

**RGE** Référentiel à Grande Échelle. 10

**RPG** Registre Parcellaire Graphique. 10, 120

**RWF** Recall Weighted Fusion. xvii, 104, 106, 107, 121, 123, 124, 140, 143

**SCoT** Schéma de Cohérence Territoriale. 4, 9, 10

**SFS** Structural Feature Set. iv, 47, 48, 121, 127, 138, 157

**SPOT** Satellite Pour l'Observation de la Terre. iv, xv, 12–15, 23, 138–143, 150, 157, 158, 160

**SVM** Séparateur à Vaste Marge. 24, 58, 59, 62, 64–69, 71, 72, 75, 85, 91, 103–105, 109–111, 159

**THR** très haute résolution. iii, iv, 12, 13, 25, 32, 39, 46, 49, 72, 95, 98, 108, 116, 138, 140, 156–158



# Annexes



# Données et résultats supplémentaires

---

■ 1 - Territoires artificialisés	■ 11 - Zones urbanisées	■ 111 - Tissu urbain continu ■ 112 - Tissu urbain discontinu
	■ 12 - Zones industrielles ou commerciales et réseaux de communication	■ 121 - Zones industrielles et commerciales ■ 122 - Réseaux routier et ferroviaire et espaces associés ■ 123 - Zones portuaires ■ 124 - Aéroports
	■ 13 - Mines, décharges et chantiers	■ 131 - Extraction de matériaux ■ 132 - Décharges ■ 133 - Chantiers
	■ 14 - Espaces verts artificialisés, non agricoles	■ 141 - Espaces verts urbains ■ 142 - Équipements sportifs et de loisirs
■ 2 - Territoires agricoles	■ 21 - Terres arables	■ 211 - Terres arables hors périmètres d'irrigation ■ 212 - Périmètres irrigués en permanence ■ 213 - Rizières
	■ 22 - Cultures permanentes	■ 221 - Vignobles ■ 222 - Vergers et petits fruits ■ 223 - Oliveraies
	■ 23 - Prairies	■ 231 - Prairies
	■ 24 - Zones agricoles hétérogènes	■ 241 - Cultures annuelles associées aux cultures permanentes ■ 242 - Systèmes culturaux et parcellaires complexes ■ 243 - Surfaces essentiellement agricoles, interrompues par des espaces naturels importants ■ 244 - Territoires agro-forestiers
■ 3 - Forêts et milieux semi-naturels	■ 31 - Forêts	■ 311 - Forêts de feuillus ■ 312 - Forêts de conifères ■ 313 - Forêts mélangées
	■ 32 - Milieux à végétation arbustive et/ou herbacée	■ 321 - Pelouses et pâturages naturels ■ 322 - Landes et broussailles ■ 323 - Végétation sclérophylle ■ 324 - Forêt et végétation arbustive en mutation
	■ 33 - Espaces ouverts, sans ou avec peu de végétation	■ 331 - Plages, dunes et sable ■ 332 - Roches nues ■ 333 - Végétation clairsemée ■ 334 - Zones incendiées ■ 335 - Glaciers et neiges éternelles
■ 4 - Zones humides	■ 41 - Zones humides intérieures	■ 411 - Marais intérieurs ■ 412 - Tourbières
	■ 42 - Zones humides maritimes	■ 421 - Marais maritimes ■ 422 - Marais salants ■ 423 - Zones intertidales
■ 5 - Surfaces en eau	■ 51 - Eaux continentales	■ 511 - Cours et voies d'eau ■ 512 - Plans d'eau
	■ 52 - Eaux maritimes	■ 521 - Lagunes littorales ■ 522 - Estuaires ■ 523 - Mers et océans

Tableau A.1 – Nomenclature hiérarchique de la base de donnée d'occupation du sol européenne Corine Land Cover













CS1. Sans végétation	CS1.1 Surfaces anthropisées	 CS1.1.1 Zones imperméables  CS1.1.2 Zones perméables	<b>CS1.1.1.1 Zones Bâties</b> <b>CS1.1.1.2 Zones non bâties (routes, parking)</b> <b>CS1.1.2.1 Zones à matériaux minéraux</b> <b>CS1.1.2.2 Zones à autres matériaux composites</b> CS1.2.1.1 Sable CS1.2.1.2 Pierres meubles (galets, éboulis ...) CS1.2.1.3 Rochers saillants ...
	CS1.2 Surfaces naturelles	 <b>CS1.2.1 Sols nus</b>  <b>CS1.2.2 Surfaces d'eau</b>	
		 <b>CS1.2.3 Neige et glaces</b>	CS1.2.3.1 Neige CS1.2.3.2 Glace
CS2. Avec végétation	CS2.1 Végétation ligneuse	 CS2.1.1 Formations arborées	<b>CS2.1.1.1 Peuplement de feuillus</b> <b>CS2.1.1.2 Peuplement de conifères</b> <b>CS2.1.1.3 Peuplement mixte</b> <b>CS2.1.1.4 Autres formations arborées</b> CS2.2.2.1 Landes basses CS2.2.2.2 Formations arbustives CS2.2.2.3 Maquis et garrigues non boisés CS2.2.2.4 Autres formations arbustives
		 <b>CS2.1.2 Formations arbustives et sous-arbrisseaux</b>  <b>CS2.1.3 Autres formations ligneuses</b>	
	CS2.2 Végétation non ligneuse	 <b>CS2.2.1 Formations herbacées</b>	CS2.2.1.1 Pelouses et prairies CS2.2.1.2 Terres arables CS2.2.1.3 Roselières CS2.2.1.4 Autres
		 <b>CS2.2.2 Autres formations non ligneuses</b>	

Tableau A.2 – Nomenclature hiérarchique de la BD d'Occupation du Sol à Grande Échelle (OCS-GE) de l'IGN : Éléments de couverture du sol, les types de couverture du sol codés dans la base OCS-GE sont représentés en gras.

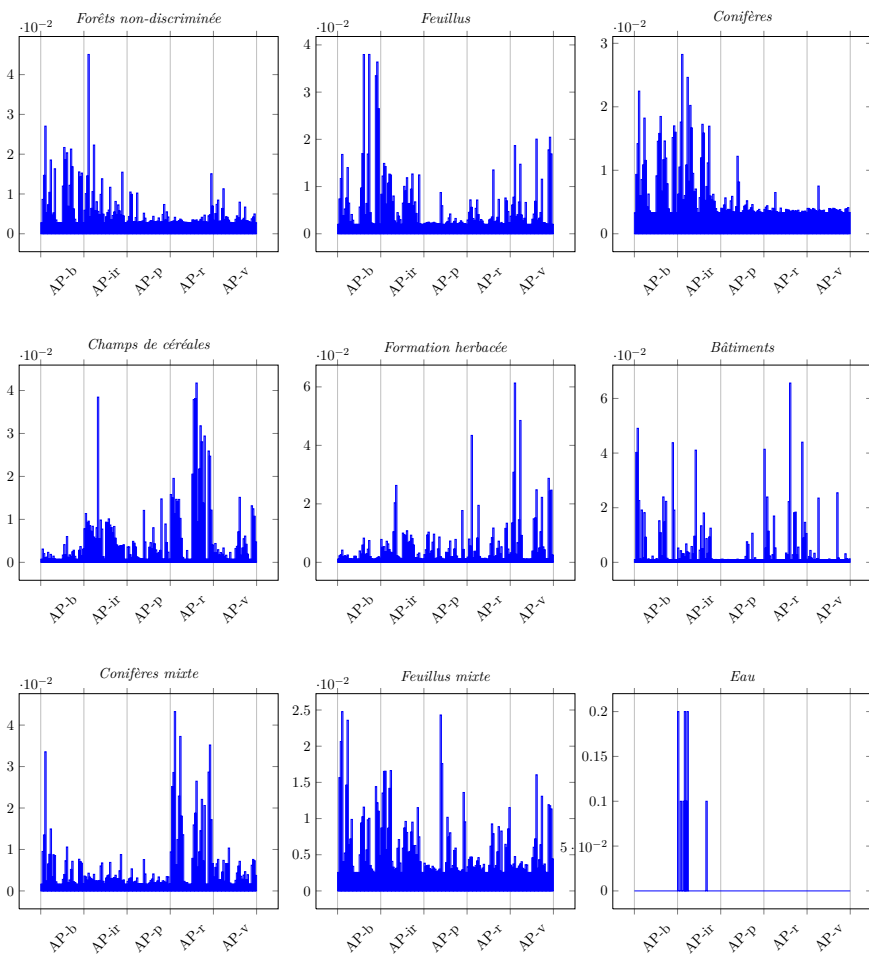


FIGURE A.1 – Importance des attributs par classe pour les profils morphologiques (AP)

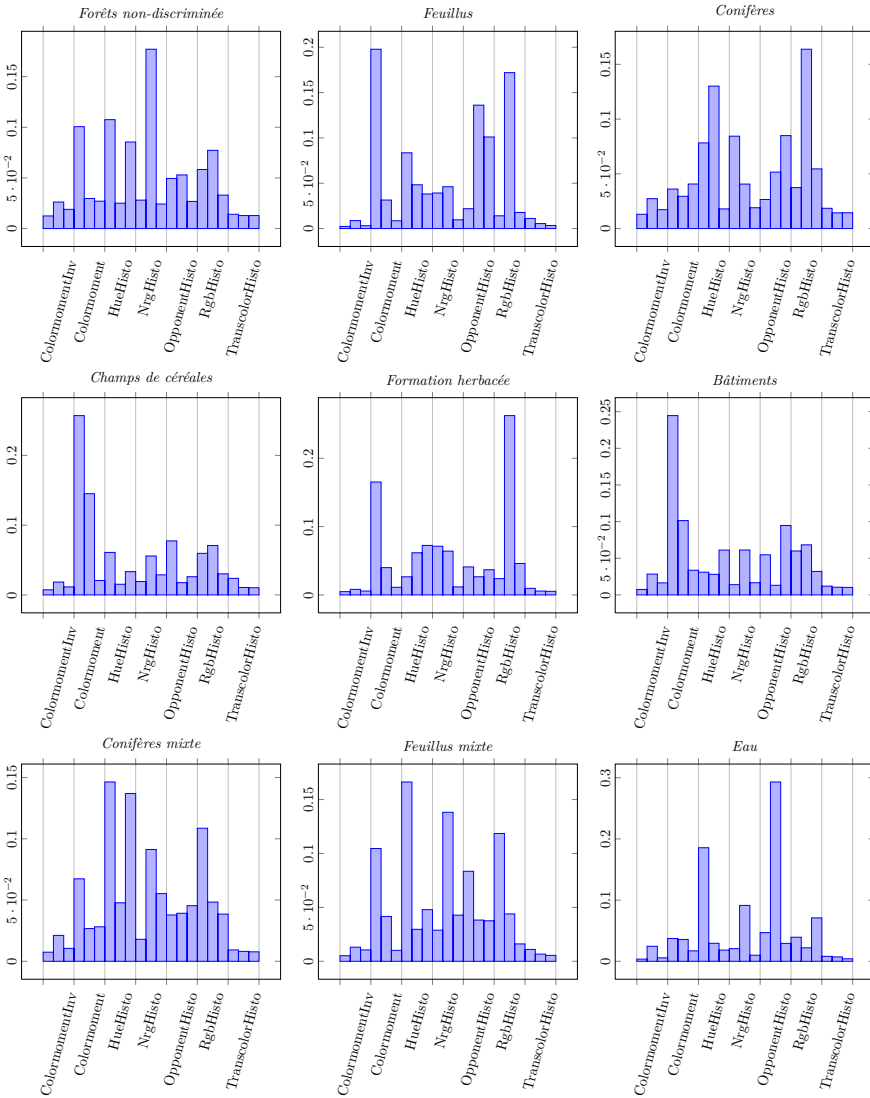


FIGURE A.2 – Importance des attributs par classe pour les attributs colorimétrique (CD)

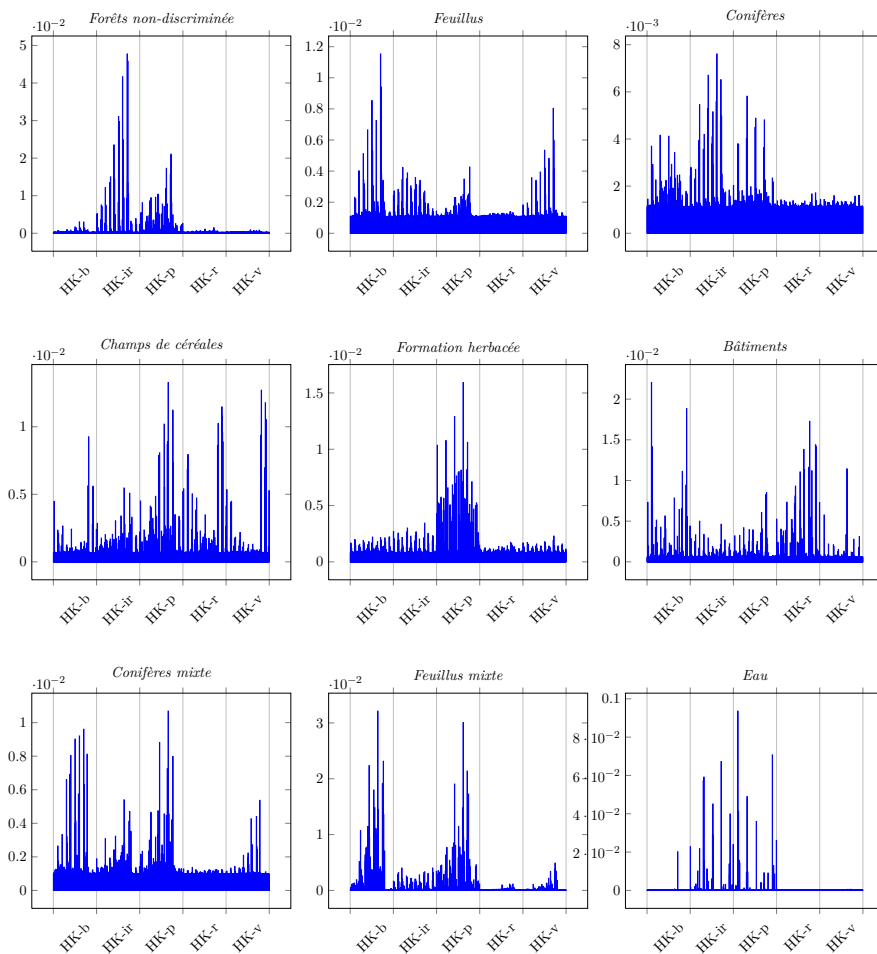


FIGURE A.3 – Importance des attributs par classe pour les attributs de textures Haralick (HK)

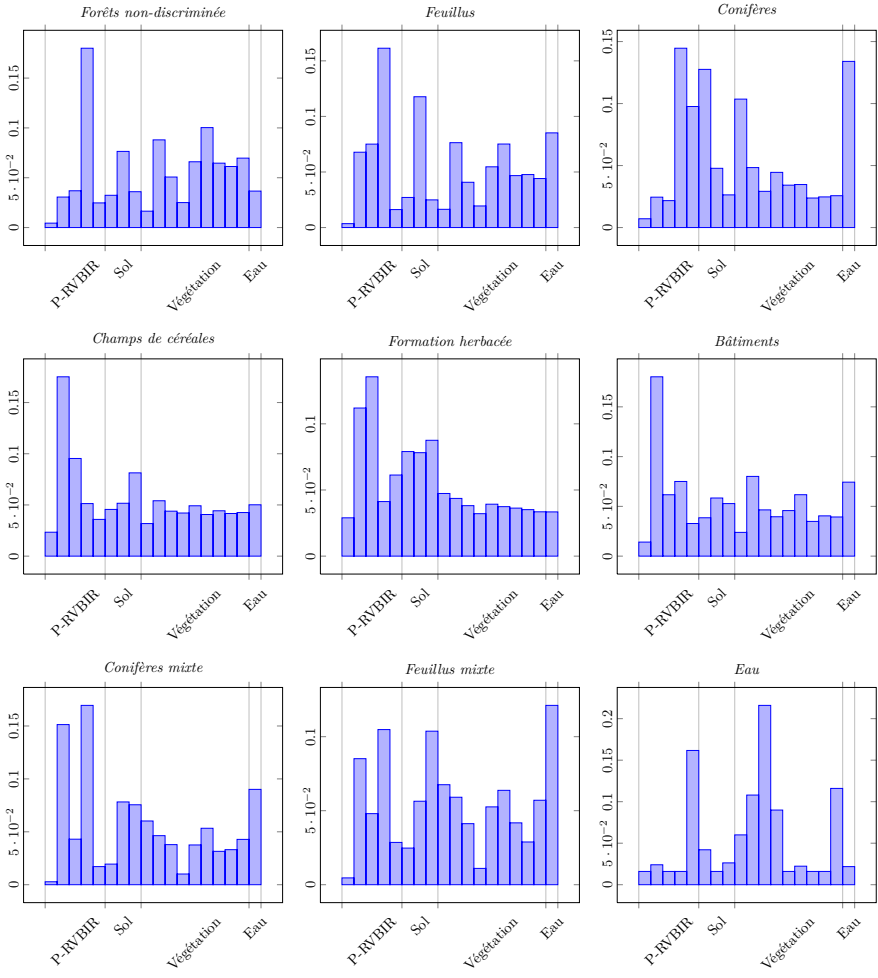


FIGURE A.4 – Importance des attributs par classe pour les attributs spectraux (SP)



# Publications

---

## Articles de revues avec comité de lecture :

**A. Gressin**, C. Mallet, N. Paparoditis et N. Vincent, 201X. Land Cover geospatial database updating using a single very high resolution satellite image. *ISPRS Journal of Photogrammetry and Remote Sensing*, *en préparation*.

**A. Gressin**, C. Mallet, N. Paparoditis et N. Vincent, 2014. Mise à jour d'une base de données d'occupation du sol à partir d'une image satellite très haute résolution : application aux données pléiades. *Revue Française de Photogrammétrie et de Télédétection* 208 ([pdf](#)).

**A. Gressin**, C. Mallet, J. Demantké et N. David, 2013. Towards 3D lidar point cloud registration improvement using optimal neighborhood knowledge. *ISPRS Journal of Photogrammetry and Remote Sensing* 79, 240-251 ([pdf](#)).

## Articles de conférences avec comité de lecture :

**A. Gressin**, N. Vincent, C. Mallet et N. Paparoditis, 2014. Extension de l'étiquetage géographique des pixels d'une image par fouille de données. 14ème conférence Extraction et Gestion des Connaissances. Rennes, France ([pdf](#)).

M. Sidi Youssef, N. Chehata, C. Mallet, A. Le Bris et **A. Gressin**, 2014. Détection de bâtiments à partir d'une image satellitaire par combinaison d'approches ascendante et descendante. *Reconnaissance de Formes et l'Intelligence Artificielle*. Rouen, France ([pdf](#)).

**A. Gressin**, C. Mallet, N. Vincent et N. Paparoditis, 2014. Updating the new French national land cover database. *IEEE International Geoscience and Remote Sensing Symposium*. Québec, Canada ([pdf](#)).

M. Sidi Youssef, C. Mallet, N. Chehata, A. Le Bris et **A. Gressin**, 2014. Combining top-down and bottom-up approaches for building detection in a single very high resolution satellite image. *IEEE International Geoscience and Remote Sensing Symposium*. Québec, Canada ([pdf](#)).

**A. Gressin**, N. Vincent, C. Mallet et N. Paparoditis, 2014. A unified framework for land-cover database update and enrichment using satellite imagery.



IEEE International Conference on Image Processing. Paris, France ([pdf](#)).

**A. Gressin**, N. Vincent, C. Mallet et N. Paparoditis, 2013. Semantic approach in image change detection. Advanced Concepts for Intelligent Vision Systems. Poznan, Pologne. ([pdf](#)).

**A. Gressin**, C. Mallet, N. Vincent et N. Paparoditis, 2013. Updating land cover databases using a single very high resolution satellite image, ISPRS Annals of Photogrammetry, Remote Sensing and Spatial Information Sciences II-3/W2, 13-18 ([pdf](#)).