



UNIVERSITÉ DE TUNIS EL MANAR

FACULTÉ DES SCIENCES DE TUNIS



UNIVERSITÉ DES ANTILLES

ET DE LA GUYANE

UFR-Science

THÈSE

présentée en vue de l'obtention du
Diplôme de Docteur en Informatique

par

Zouhour BEN DHIAF

Fusion de sources d'informations pour l'interprétation d'images de télédétection moyenne et haute résolution : Application à l'inventaire forestier

soutenue le 28 mars 2011, devant le jury d'examen

MM.	Zaher MAHJOUB	Prof. FST	Président
	I.Riadh FARAH	M.C. ISAMM	Rapporteur
	Hedi El-ZAHZAH	M.C. U.R	Rapporteur
	Basel SOLAIMAN	M.C. T.BR	Examineur
	Khaled BSAIES	Prof. FST	Directeur de thèse
J	acky DESACHY	Prof. UAG	Directeur de thèse

préparée sous convention de cotutelle UTM-FST (Tunisie) – UAG-Guadeloupe (France)

TABLE DES MATIÈRES

INTRODUCTION	3
CHAPITRE I	9
<i>Généralités sur les approches de fusion de sources d'informations</i>	9
I.1 Introduction	9
I.2 Imperfections de l'information	9
I.2.1 Élément d'information parfait	10
I.2.2 Imperfections d'un élément d'information	10
I.2.3 Approches de gestion de l'imperfection d'un élément d'information	12
I.3 Sources d'informations	13
I.3.1 Exemples de sources d'informations	14
I.3.2 Modélisation des sources d'information	15
I.3.3 Types de sources et relations entre sources	15
I.3.4 Typologie de la fusion d'informations	16
I.4 Formalismes de fusion de sources d'informations	16
I.4.1 Fusion probabiliste	17
I.4.2 Fusion possibiliste	21
I.4.3 Fusion dans la théorie des fonctions de croyance	26
I.5 Probabilités, possibilités, croyances : Choix d'une théorie	32
I.6 Conclusion	33
CHAPITRE II	39
<i>Théorie des fonctions de croyance</i>	39
II.1 Introduction	39
II.2 Modèle de croyance transférable	39
II.2.1 Niveau crédal et niveau pignistique	39
II.2.2 Règle de conditionnement	41
II.2.3 Matrice de spécialisation	42
II.2.4 Intérprétation et gestion du conflit par la MCT	42
II.2.5 Intérêt	43
II.2.6 Limites	44
II.3 Théorie de Dezert-Smarandache	46
II.3.1 Principe général	46

II.3.2	Cadre de discernement généralisé _____	47
II.3.3	Jeu de masses généralisé _____	48
II.3.4	Fonctions de croyance et de plausibilité généralisées _____	48
II.3.5	Transformation pignistique généralisée _____	49
II.3.6	Intérêt : Gestion du conflit avec la théorie de Dezert-Smarandache _____	49
II.4	Justification du choix de la théorie des fonctions de croyance _____	50
II.5	Conclusion _____	52
CHAPITRE III _____		55
<i>Application de la théorie des fonctions de croyance à la classification d'images _____</i>		55
III.1	Introduction _____	55
III.2	Raisonnement évidentiel flou _____	55
III.2.1	Motivations _____	55
III.2.2	Généralisation de la théorie des croyances aux ensembles flous _____	57
III.3	Détermination des éléments focaux _____	62
III.4	Approches d'estimation des fonctions de masse pour la classification d'images _____	64
III.4.1	Familles de méthodes d'estimation des fonctions de masse _____	64
III.4.2	Estimation des fonctions de masse sur des sous-ensembles flous _____	65
III.5	Conclusion _____	68
CHAPITRE IV _____		70
<i>Solutions proposées pour la réduction de la complexité _____</i>		70
IV.1	Introduction _____	70
IV.2	Complexité exponentielle de l'application de la fusion par la théorie des fonctions de croyance _____	70
IV.2.1	Complexité par source d'information _____	70
IV.2.2	Complexité de la fusion de sources à travers l'opérateur orthogonal de Dempster _____	71
IV.2.3	Prise de décision _____	71
IV.3	Etat de l'art des approches de réduction de la complexité _____	71
IV.3.1	Algorithme de Barnett _____	72
IV.3.2	Transformation rapide de Möbius _____	72
IV.3.3	Propagation dans les arbres _____	72
IV.3.4	Méthodes d'approximations _____	72
IV.4	Solution proposée pour la réduction de la complexité _____	74
IV.4.1	Réduction du référentiel de définition _____	74

Table des matières	iii
IV.4.2 Choix contextuel des sources _____	78
IV.5 Etude expérimentale et évaluation des performances _____	80
IV.6 Conclusion _____	85
CHAPITRE V _____	88
<i>Estimation des fonctions de masse : Méthodes et approches proposées _____</i>	88
V.1 Introduction _____	88
V.2 Approche spectrale d'estimation des fonctions de masse _____	88
V.2.1 Méthode d'estimation des fonctions de masse avec passage par les distributions de possibilités _____	88
V.2.2 Calcul des distributions de possibilités _____	89
V.2.3 Calcul des fonctions de masse d'évidence _____	90
V.2.4 Calcul direct des fonctions de masse d'évidence _____	90
V.3 Approche multifractale pour la caractérisation de la texture _____	91
V.3.1 Notion de texture et méthodes de représentations _____	91
V.3.2 Utilisation de l'outil multifractal _____	92
V.3.3 Construction de la mesure multifractale _____	92
V.3.4 Estimation des exposants de singularités _____	93
V.3.5 Estimation des fonctions de masses à partir des histogrammes des exposants de singularité _____	94
V.4 Estimation des fonctions de masse à partir de l'information contextuelle forestière _____	94
V.4.1 Introduction _____	94
V.4.2 Algorithmes de détection des couronnes d'arbres _____	95
V.4.3 Intégration de l'information contextuelle pour le transfert des croyances dans un système de fusion de sources d'informations – Application à la détection et la classification des couronnes _____	107
V.5 Conclusion _____	109
CHAPITRE VI _____	112
<i>Architecture d'un système de fusion de sources d'informations basé sur la théorie des fonctions de croyance et appliqué pour le contexte forestier _____</i>	112
VI.1 Introduction _____	112
VI.2 Apprentissage _____	114
VI.2.1 Source d'information image moyenne résolution SPOT _____	114
VI.2.2 Source d'information image haute résolution QuickBird _____	116
VI.3 Illustration de la réduction du référentiel de définition _____	121
VI.3.1 Choix des hypothèses du cadre de discernement _____	121
VI.3.2 Apport au niveau complexité temporelle _____	121
VI.4 Classification et estimation des fonctions de masse de l'IMR _____	123

VI.4.1	Estimation des fonctions de masse à travers les histogrammes de niveaux de gris _____	124
VI.4.2	Estimation des fonctions de masse à travers les histogrammes des exposants de singularités _____	126
VI.5	Exploration de l'IHR : Estimation des masses et révision _____	127
VI.5.1	Estimation des fonctions de masse à travers les histogrammes _____	127
VI.5.2	Fusion des sources image et inventaire _____	131
VI.5.3	Fusion contextuelle _____	135
VI.6	Evaluation globale du système de fusion _____	141
VI.6.1	Interprétation numérique _____	142
VI.6.2	Analyse visuelle de la classification _____	146
VI.7	Conclusion _____	149
CONCLUSION ET PERSPECTIVES _____		153
RÉFÉRENCES BIBLIOGRAPHIQUES _____		158
ANNEXE A _____		171
Règles de gestion du conflit _____		171
A.1	Alternatives à la règle de Dempster _____	171
A.1.1	Opérateur de Yager _____	171
A.1.2	La combinaison proposée par Dubois et Prade _____	172
A.1.3	Affaiblissement _____	173
A.1.4	Approches de redistribution du conflit (PCR) : Proportional conflict redistribution _____	173
A.1.5	Règle de combinaison adaptative (ACR) : Adaptive Combination Rule _____	174
A.1.6	Classification des règles de combinaison _____	174
A.2	Cadre générique pour les opérateurs de combinaison _____	175
ANNEXE B _____		178
Zone d'étude et sources d'informations disponibles _____		178
B.1	Zone d'étude _____	178
B.2	Sources d'informations _____	179
B.2.1	Image SPOT moyenne résolution _____	179
B.2.2	Image QuickBird très haute résolution _____	180
B.2.3	Inventaire Forestier National (IFN) _____	181
B.2.4	Le Modèle Numérique du Terrain (MNT) _____	186
B.2.5	Diversité des espèces _____	186
B.3	Méthode de mise en œuvre de l'inventaire forestier national _____	187
B.4	Nomenclature utilisée pour le codage de l'inventaire forestier national _____	188

<i>ANNEXE C</i>	<i>191</i>
<i>Application de l'algorithme de croissance de régions par mouvement Brownien :</i>	
<i>Paramétrage de l'algorithme</i>	<i>191</i>
C.1 Détermination des maximums locaux	191
C.2 Extraction des couronnes d'arbres	193

LISTE DES FIGURES

Figure I.1 . <i>Choix d'un langage de modélisation des imperfections de l'information D'après [Ben Amor 2004]</i>	34
Figure II.1. <i>Histogrammes des zones d'apprentissages des classes du cadre de discernement avec chevauchements</i>	52
Figure IV.1. <i>Détermination des histogrammes des éléments focaux composés</i>	77
Figure IV.2. <i>Architecture d'un processus de fusion basé sur un choix contextuel de sources</i>	79
Figure IV.3. <i>Histogrammes des classes des zones d'apprentissages de la fenêtre 1 de l'IHR</i>	80
Figure IV.4. <i>Histogrammes des classes des zones d'apprentissage et leurs chevauchements</i>	81
Figure IV.5. <i>Chevauchements mineurs entre les histogrammes (normalisés) des classes</i>	81
Figure IV.6. <i>Histogrammes des classes des zones d'apprentissage et leurs chevauchements pour $p=0.1$</i>	81
Figure IV.7. <i>Histogrammes de classes occultées dans la figure IV.6</i>	82
Figure IV.8. <i>Histogrammes des classes des zones d'apprentissage et leurs chevauchements pour $p=0.2$</i>	82
Figure IV.9. <i>Evolution du nombre de classes en fonction du rapport de surface de chevauchement</i> ..	83
Figure IV.10. <i>Choix des zones d'apprentissages des classes de Ω et histogrammes superposés de ces zones pour l'IMR</i>	84
Figure IV.11. <i>Histogrammes des zones d'apprentissages des classes de Ω pour l'IMR</i>	84
Figure IV.12. <i>Evolution du nombre de classes en fonction du rapport de surface de chevauchement pour l'exemple de l'IMR</i>	85
Figure V.1. <i>Extrait d'une carte topographique 3D d'une portion de forêt</i>	96

Figure V.2. <i>Extrait d'une carte topographique 3D d'une portion de forêt.</i>	97
Figure V.3. <i>Diagramme des étapes de l'algorithme de Croissance de Régions par Mouvement Brownien.</i>	98
Figure V.4. <i>Différentes formes de patrons.</i>	99
Figure V.5. <i>Prise de vue des photographies aériennes et point Nadir : projeté orthogonal sur le sol de la caméra.</i>	100
Figure V.6. <i>Résultat de l'extraction des couronnes selon G.Perrin [Perrin 2006] sur une fenêtre d'une image d'une plantation de peupliers.</i>	101
Figure V.7. <i>Représentation d'une image sous forme de terrain 3D et remplissage des bassins avec de l'eau.</i>	102
Figure V.8. <i>Détermination des couronnes d'arbres par opérateurs LPE et ouverture de la MM.</i>	103
Figure V.9. <i>Extraction des couronnes par ECMB, SV, MA.</i>	104
Figure V.10. <i>Extraction des arbres sur une fenêtre d'une image aérienne infrarouge coloré d'une zones éparses avec les algorithmes PPM et CR</i>	105
Figure V.11. <i>Extraction des arbres sur une fenêtre d'une image aérienne infrarouge colorée d'une zone dense avec les algorithmes PPM et CR.</i>	105
Figure V.12. <i>Extraction des arbres sur une fenêtre d'une image aérienne infrarouge colorée d'une zone dense avec les algorithmes PPM et CR.</i>	106
Figure VI.1. <i>Architecture de notre système de fusion.</i>	113
Figure VI.2. <i>Image Spot de la zone d'étude, IFN et choix des zones d'apprentissage.</i>	115
Figure VI.3. <i>Histogrammes des zones d'apprentissages des classes choisies sur l'IMR.</i>	115
Figure VI.4. <i>Image de Hölder obtenue à partir de l'IMR et histogramme des exposants de singularités des zones d'apprentissage correspondants.</i>	116
Figure VI.5. <i>Fenêtre 1 de l'IHR QuickBird et IFN correspondant.</i>	117
Figure VI.6. <i>Fenêtre 2 de l'image haute résolution et IFN correspondant.</i>	118
Figure VI.7. <i>Zones d'apprentissages choisies sur la fenêtre2 de l'IHR.</i>	119
Figure VI.8. <i>Fenêtre3 de l'IHR ainsi que son IFN et le choix des zones d'apprentissage.</i>	120

Figure VI.9. <i>Image de Hölder obtenue à partir de la fenêtre 3 de l'IHR et les histogrammes des exposants de singularités des zones d'apprentissage correspondantes.</i>	121
Figure VI.10. <i>Courbes de réduction du référentiel de définition en fonction du seuil correspondantes à la fenêtre 2.</i>	122
Figure VI.11. <i>Courbes de réduction du référentiel de définition en fonction du seuil correspondantes à la fenêtre 1.</i>	123
Figure VI.12. <i>Classification spectrale par maximum de masse de l'image moyenne résolution.</i>	124
Figure VI.13. <i>Classification spectrale par maximum de masse des échantillons choisis sur l'IMR...</i>	125
Figure VI.14. <i>Classification de l'image de Hölder de l'IMR par maximum de masse.</i>	126
Figure VI.15. <i>Choix des zones d'apprentissages et classification spectrale par maximum de masse de la fenêtre3 de l'IHR.</i>	128
Figure VI.16. <i>Classification spectrale par maximum de masse de la fenêtre4 de l'IHR.</i>	129
Figure VI.17. <i>Classification texturale par maximum de masse de la fenêtre3 de l'IHR.</i>	130
Figure VI.18. <i>Classification texturale par maximum de masse de l'image de Hölder de la fenêtre 4 de l'IHR.</i>	131
Figure VI.19. <i>Choix des zones d'apprentissages sur la fenêtre 1 de l'IHR.</i>	132
Figure VI.20. <i>Classification de la fenêtre 1 de l'IHR par maximum de masses, de crédibilités, de plausibilités et de probabilités pignistique.</i>	133
Figure VI.21. <i>Classification par fusion de l'image et de l'inventaire par maximum de masses avec différents facteurs d'affaiblissement de l'inventaire.</i>	134
Figure VI.22. <i>Extraction des couronnes de la fenêtre 4 de l'IHR par ECBM.</i>	136
Figure VI. 23. <i>Résultat de la classification par maximum de masse de la fenêtre 4 de l'IHR après révision de la distribution de masse texturale par l'information couronne et fusion avec l'information structurelle.</i>	138
Figure VI.24. <i>Extraction des couronnes de la fenêtre 5 de l'IHR par ECBM.</i>	138
Figure VI.25. <i>Exploitation de l'information contextuelle : application sur la fenêtre 5 de l'IHR</i>	139
Figure VI.26. <i>Exploitation de l'information contextuelle issue de l'IFN : application sur la fenêtre 6 de</i>	

<i>l'IHR</i>	140
Figure VI.28. Valeurs du facteur kappa pour les cinq méthodes	145
Figure VI.29. Courbes des erreurs d'omission et de commission pour les huit classes selon les cinq méthodes.....	145
Figure VI.30. Classification par notre méthode M1 de la fenêtre f3.....	147
Figure VI.31. Classification par la méthode M2 la fenêtre f3.....	147
Figure VI.32 Classification par la méthode M3 de la fenêtre f3.....	148
Figure VI.33. Classification la méthode M4 de la fenêtre f3	148
Figure VI.34. Classification la méthode M5 de la fenêtre f3	149
Figure B.1. Présentation de la zone d'étude.	178
Figure B.2. Présentation de l'Image Spot moyenne résolution de notre zone d'étude.....	179
Figure B.3. Image QuickBird de la scène d'étude et quelques fenêtres de cette image.	181
Figure B.4. Inventaire de la zone d'étude en strates.	182
Figure B.5. Inventaire correspondant à une fenêtre de l'image QuickBird	183
Figure B.6. Exemples de fenêtres de l'IHR et inventaires correspondants.	185
Figure B.7. MNT de la zone d'étude.....	186
Figure B.8. Nomenclature utilisée pour l'inventaire forestier national.	189
Figure C.1. Extraction des maximums locaux sur une image de l'IHR correspondant à une forêt éparse avec l'algorithme ECMB pour des masques de différentes tailles.	191
Figure C.2. Extraction des maximums locaux sur une image de l'IHR correspondant à une forêt dense avec l'algorithme ECMB pour des masques de différentes tailles.	192
Figure C.3. Résultats de segmentation avec deux seuils différents 0.5 et 0.7.....	193
Figure C.4. Segmentation avec deux nombre de pas différents (100000 et 1000).....	194
Figure C.5. Segmentation d'un groupement de chêne zen dense.	194
Figure C.6. Segmentation d'un groupement de chêne zen épars.....	195

Figure C.7. <i>Segmentation d'un groupement de chêne liège.</i>	195
Figure C.8. <i>Segmentation d'un groupement d'arboretum.</i>	196
Figure C.9. <i>Segmentation d'un groupement de forêt de résineux.</i>	196

LISTE DES TABLEAUX

Tableau II.1. Comparaisons entre TDS et MCT	46
Tableau VI.1. Matrice de confusion de la classification spectrale par maximum de masse de l'image moyenne résolution.	125
Tableau VI.2. Matrice de confusion de la classification texturale par maximum de masse de l'IMR.	126
Tableau VI.3. Matrice de confusion de la classification spectrale par maximum de masse de la fenêtre 3 de l'IHR.	127
Tableau VI.4. Matrice de confusion de la classification spectrale par maximum de masse de la fenêtre 4 de l'IHR.	129
Tableau VI.5. Matrice de confusion de la classification texturale par maximum de masse de la fenêtre 3 de l'IHR.	130
Tableau VI.6. Matrice de confusion de la classification par maximum de masses et matrices de répartition des affectations des échantillons sur les éléments focaux obtenus suite à la classification par maximum de crédibilités et par maximum de plausibilités.	134
Tableau VI.7. Evaluation de la classification des couronnes de la fenêtre 4.	137
Tableau VI.8. Evaluation de la classification des couronnes de la fenêtre 2.	139

INTRODUCTION

INTRODUCTION

La prolifération des moyens d'acquisition de données de télédétection ainsi que l'émergence des systèmes satellitaires de haute résolution, ont élargi le champ d'application du traitement d'images numériques. Les diverses techniques de classification se basant sur l'information extraite d'une même source ne répondent pas efficacement à tous les besoins en matière de cartographie. En effet, les résultats des algorithmes de classification mono-source de données laissent apparaître des problèmes de confusion.

C'est ainsi que la recherche dans ce domaine a été axée à l'identification de nouvelles approches. Les premières approches permettant de traiter ce problème faisaient intervenir, parallèlement à l'image à interpréter, une autre donnée sur la scène modélisée sur un plan de correspondance qui offre une connaissance exogène sur cette même scène. Il en résulte que la multiplication des sources de données dans l'interprétation automatique d'images assure un cadre idéal pour la classification des différentes formations de la surface terrestre.

Ainsi, vu l'insuffisance des informations issues d'une seule source (incertitude et imprécision), la tendance dans les recherches actuelles est penchée vers des approches de classification multi-sources permettant de fusionner les informations issues des différentes sources [Dubois et Prade 1994] [Bloch 1996 c] [Bloch 2005]. Chaque source de données apporte une information complémentaire qui pourra orienter dans le bon sens la décision d'affecter un pixel de l'image à une classe bien déterminée.

Notre travail est orienté vers une application du système de fusion dans le domaine de la cartographie des zones forestières. Les sources d'information sont des images satellitaires en moyenne et haute résolution, un inventaire forestier [IFNT 2000], et des connaissances expertes sur la zone d'étude.

Ces sources sont multi dates et multi résolutions et présentent donc des imprécisions dues aux évolutions des limites entre les formations forestières dans le temps et à la différence de résolutions entre les sources images. De plus, ses sources sont tachées d'incertitude puisque des changements radicaux dus par exemple à des catastrophes naturelles changent l'état de la scène, par rapport à son état, à une date d'acquisition antérieure.

Le premier problème est donc de choisir un formalisme de fusion. La théorie des fonctions de croyance (TFC) est celle que nous avons retenue comme formalisme de fusion de sources

d'information. Cette théorie est la plus récente parmi les formalismes de fusion. Des recherches ont montré qu'elle intègre les théories des probabilités et des possibilités en tant que cas particuliers de cette théorie dans le cas d'hypothèses singletons ou emboîtées respectivement [Smets 1998]. La théorie des possibilités et la théorie des croyances se distinguent par rapport à la théorie des probabilités par la prise en compte de l'imprécision et de l'incertitude.

Les applications de la TFC à la classification d'images aboutissent à l'affectation de chaque point de l'image à une classe ou à un sous ensemble de classes. La décision peut être basée sur la maximisation des fonctions de masses de croyances, de crédibilités ou de plausibilités. La décision est repoussée vers l'étape finale après fusion des différentes propositions de classifications des points de l'image fournies par chacune des sources.

Il a été souvent reproché à la TFC d'engendrer des temps de calcul particulièrement importants lorsque la cardinalité du cadre de discernement (ensemble des hypothèses possibles, classes en classification) devient grande. Ainsi, une limite majeure de l'application de la TFC dans la fusion de sources d'informations est la complexité combinatoire qui croît proportionnellement avec le nombre de classes et le nombre de sources [Barnett 1981] [Shafer 1990] [Haenni et Lehmann 2003].

D'autre part, la TFC est basée sur l'estimation de fonctions appelées fonctions de masses de croyance qui expriment la confiance d'un événement (selon une source). Il n'existe pas de méthode universelle pour l'estimation de ces fonctions mais ceci dépend du cas d'application [Bell et al. 2005],[Bloch 2008],[Bloch et maitre 2004], [Denoeux 2005], [Guo et al. 2006], [Hammal et al. 2004], [Hammal et al. 2007], [Jouan et Allard 2004], [Lefevre 1999], [Vanoorenberghe 2003], [Vanoorenberghe et al. 2003].

Un autre aspect de la fusion est le conflit entre sources d'informations. Le conflit caractérise deux ou plusieurs informations conduisant à des interprétations contradictoires et donc incompatibles. Les situations conflictuelles sont fréquentes dans les problèmes de fusion, et posent toujours des problèmes difficiles à résoudre. Les sources d'informations peuvent générer un taux de conflit important dans le cas de sources discordantes [Lefevre et al. 2001] [Martin et Osswald 2007] [Smarandache et Dezert 2006].

Cette thèse vise à définir, dans le cadre d'un système d'interprétation semi-automatique d'images de télédétection, un processus de fusion d'une multitude de sources d'informations sur une scène et de l'appliquer pour étudier l'apport d'une telle approche dans la fiabilité recherchée de la classification résultante.

Nous proposons tout d'abord de résoudre le problème d'explosion combinatoire. La diversité des espèces forestières dans notre zone d'étude implique un grand nombre de classes

(14 strates présentes dans l'inventaire de la zone d'étude). Aussi, le nombre de sources est important puisqu'on dispose de deux images moyenne et haute résolution, de l'inventaire numérisé, du modèle numérique du terrain, images de Hölder, de l'image des couronnes et des connaissances expertes qui seront introduites en tant que source.

Nous proposons ensuite, des méthodes d'estimation des distributions de masses de croyances adaptées à nos sources et notre scène. Vu la qualité de la source image haute résolution, nous nous proposons de fournir des solutions adéquates. Pour cela, nous essayons tout d'abord de profiter des propriétés des sources images fournissant l'information spectrale et texturale.

En effet, l'implication de l'information de texture apporte une richesse considérable dans la caractérisation des classes d'appartenance et il importe donc de prendre en considération cette donnée dans l'estimation des fonctions de masse dans le processus de classification multi-sources. Le but étant d'opter pour une méthode qui s'accommode le plus avec la nature des images haute résolution. L'utilisation de l'information multi fractale a montré son efficacité pour dégager l'information de texture. L'analyse multi fractale des images consiste à définir des mesures à partir des niveaux de gris, et fournit une description à la fois locale et globale de l'image [Muzzy 1993],[Véhel et Vojak 1995],[Grazzini et al. 2006]. Nous utilisons cette information multi fractale de l'image pour dégager des fonctions de masse associées.

De plus, l'exploitation de la richesse de l'image haute résolution en matière de couverture forestière dégage l'identification de structures telles que les couronnes d'arbre et l'utilisation de l'image des couronnes comme source d'information. Nous proposons d'extraire des informations contextuelles permettant de réviser les distributions de masses initiales par l'information couronne et inventaire (objet) basée sur la Modèle de Croyance Transférable [Smets 2000].

L'analyse du conflit résultant de la combinaison de toutes les sources fait apparaître une forte corrélation avec le contexte. Souvent, l'implication d'une source d'information dans un processus de fusion dégage des performances contradictoires selon des cas d'utilisation différents. Ceci s'explique par le fait que la fiabilité de l'information fournie par une source est fonction de variables contextuelles, Nous proposons la prise en compte du contexte pour réduire à la fois ce conflit et aussi la complexité des calculs des masses combinées. Nous proposons une solution au conflit entre sources (choix d'un sous ensemble de sources par contexte).

Ainsi, ce travail a pour objectif de mettre en place un système de fusion de sources d'informations basé sur la théorie des fonctions de croyance et adapté aux contextes des images forestières hautes résolution en particulier.

Le chapitre I présente un état de l'art des formalismes de fusion de sources d'informations. En effet, il présente le résultat d'une recherche bibliographique étendue sur ces formalismes et théories sous-jacentes.

Le chapitre II dresse un état de l'art sur la théorie des fonctions de croyance (TFC) qui est celle que nous avons retenue comme formalisme de fusion de sources d'information. Cette théorie a vécu des interprétations et des extensions diverses au cours du temps qui ont donné lieu à des variantes à cette théorie. Nous consacrons ce chapitre II à l'étude de ces variantes : le modèle des croyances transférables et la théorie de Dezert-Smarandache (théorie du raisonnement plausible et paradoxal).

Le chapitre III présente un état de l'art concernant les applications de la TFC de la fusion à la classification d'images. Il est consacré à la définition des éléments focaux (nets et flous) et à l'état de l'art pour les approches d'estimation des fonctions de masse pour la classification d'images.

Le chapitre IV détaille notre première contribution qui consiste en une solution pour la réduction de la complexité de la TFC. Ce chapitre est dédié au problème combinatoire engendré par les estimations et combinaisons de fonctions de masses de croyances issues de différentes sources.

Le chapitre V est dédié à notre deuxième contribution concernant le volet estimation des fonctions de masses qu'on divisera en des méthodes se basant sur l'information spectrale, texturale et la révision par l'information couronne et polygones inventaire (objets).

Le Chapitre VI présente l'architecture du système proposée et l'évaluation numérique des apports qui tracent notre processus de fusion et les résultats de l'application de notre approche de classification sur des fenêtres des images de la scène étudiée.

Nous terminons ensuite par des conclusions et des perspectives de ce travail.

Deux annexes viennent à la fin de ce rapport :

L'Annexe A est consacré aux règles de gestion du conflit les plus utilisées

L'Annexe B présente les sources d'informations se référant à la zone d'étude.

L'annexe C illustre le paramétrage de l'algorithme de croissance de régions par mouvement Brownien avec l'application sur des fenêtres de notre image Quickbird.

CHAPITRE I

GENERALITES SUR LES APPROCHES DE FUSION DE SOURCES D'INFORMATIONS

CHAPITRE I

Généralités sur les approches de fusion de sources d'informations

I.1 Introduction

Dans ce chapitre, nous allons introduire les théories qui permettent la fusion de sources d'information ainsi que les différents modèles qui servent à les décrire et à les classer. Nous présentons le modèle probabiliste, le modèle possibiliste et le modèle issu des fonctions de croyance. Chacun de ces modèles s'articule sur un formalisme et introduit un moyen de décision pour pallier à l'imperfection et l'incertitude des sources d'informations. Ces modèles offrent des opérateurs de combinaison pour profiter de la complémentarité des sources et des connaissances qu'elles apportent dans la caractérisation d'un élément d'information. Pour chacun de ces modèles, nous présentons son formalisme, l'estimation de la fonction qu'il introduit (fonction de probabilité pour le modèle probabiliste, fonction d'appartenance pour le modèle possibiliste et fonction de masse pour le modèle évidentiel), l'opérateur (ou les opérateurs) de combinaison, les règles de décision et une discussion sur leurs apports dans les applications où ils sont couramment utilisés. Enfin, nous concluons en présentant une synthèse sur ces différents modèles.

I.2 Imperfections de l'information

La fusion d'information consiste à combiner des informations issues de plusieurs sources afin d'améliorer la prise de décision [Bloch 2005]. Ces sources peuvent être de types différents et fournissent des informations généralement imparfaites. Pour mettre en œuvre une procédure de fusion, il faut tout d'abord résoudre les problèmes de modélisation de l'imperfection des informations produites par les sources. Cette section est consacrée à la définition de ces imperfections de l'information et introduit les approches qui permettent de les manipuler.

I.2.1 Élément d'information parfait

Un élément d'information est défini comme étant une application E qui associe chaque objet d'un espace de définition avec un ou plusieurs objets d'un espace des contenus informationnels.

Soient :

- I_D l'espace de définition
- I_C l'espace des contenus informationnel
- O un objet de I_D
- C un objet de I_C

Selon B. Solaiman [Solaiman 2001], un élément d'information est considéré parfait s'il vérifie les propriétés suivantes :

Exhaustivité

Pour tout objet $O \in I_D$, il existe un contenu $C \in I_C$ tel que $C = E(O)$.

Cette hypothèse est aussi appelée l'hypothèse du monde fermé (*closed world*).

Exclusivité

Pour tout objet $O \in I_D$, le contenu informationnel associé à O est unique.

Précision

La connaissance apportée par $E(O)$ est un singleton et non un sous ensemble de I_C .

Certitude

La connaissance apportée par est certaine s'il n'existe aucun doute concernant l'identité du contenu informationnel associé.

Un élément d'information est dit parfait s'il est parfait pour tous les objets .

I.2.2 Imperfections d'un élément d'information

A partir de la définition d'un élément d'information parfait, nous allons définir les différents types d'imperfection d'un élément d'information.

Imprécision

Un élément d'information est imprécis si :

1. Il est exhaustif.
2. Il est exclusif.
3. Pour chaque objet O , l'information apportée par $E(O)$ ne permet pas d'obtenir une connaissance précise de C tel que $C = E(O)$. Le contenu informationnel C est donné par l'intermédiaire d'un sous-ensemble A tels que $C \in A \subseteq I_C$. De plus, nous ne disposons d'aucune connaissance permettant de favoriser un contenu par rapport à un autre au sein de I_C .

L'imprécision concerne le contenu de l'information et mesure donc un défaut quantitatif de connaissance, sur une mesure. Elle fait plutôt référence à des informations de type numérique (exemple : « l'altitude est de 1 km plus ou moins 10 m ») et concerne le manque d'exactitude en quantité, en taille, en durée, le manque de définition d'une proposition qui est ouverte à diverses interprétations ou qui a des frontières vagues et mal définies. L'information étant définie sur un espace continu ou non, l'imprécision correspond à la partie de cet espace à laquelle cette information peut appartenir.

Incertitude

Un élément d'information est dit incertain si la source associée est caractérisée par un degré de véracité. L'incertitude fait référence à la nature de l'objet ou du fait concerné, à sa qualité, à son essence ou à son occurrence.

Certains auteurs choisissent de distinguer deux types d'*incertitude* :

- l'*incertitude objective* que l'on peut assimiler à de l'aléa (on dispose d'un système de mesure sujet à une certaine variabilité, par exemple la technique d'échantillonnage).
- l'*incertitude subjective* essentiellement liée au crédit que l'on accorde à la source.

D'autres termes sont souvent utilisés faisant référence aux approches manipulant chaque type d'incertitude :

- *incertitude probabiliste*,
- *incertitude possibiliste*,
- *incertitude crédibiliste*.

Ph. Smets [Smets 1998] définit de manière informelle les notions d'imprécision et d'incertitude. Il considère qu'il y'a imprécision à chaque fois que la valeur exacte du vrai statut d'une proposition d'intérêt n'est pas établie de façon unique (c.-à-d. à chaque fois que son statut est douteux). L'incertitude est une information ajoutée qui exprime l'idée que la vérité de

certaines propositions est mieux supportée que la vérité d'autres propositions.

Ambigüité

Un élément d'information est dit ambigu si :

1. Il est exhaustif.
2. Il n'est pas exclusif. Ceci signifie que pour chaque objet O , tous les contenus informationnels $C \in I_C$ sont partiellement associés à O . Cette association partielle est modélisée par l'intermédiaire d'une fonction d'appartenance $\mu_{E(O)}(C) \in [0,1]$.

L'ambigüité exprime la capacité d'une information de conduire à deux interprétations. Elle peut provenir des imperfections précédentes.

Outre l'imprécision, l'incertitude et l'ambigüité, s'ajoutent d'autres imperfections de l'information telles que l'incomplétude, la redondance, la complémentarité, le conflit. Des définitions étendues ainsi que quelques mesures de ces éléments d'imperfection de l'information sont précisées par des auteurs tels que A.Martin dans [Martin 2005]. Les propriétés d'exhaustivité et d'exclusivité sont respectivement contradictoires à l'incomplétude et la redondance.

I.2.3 Approches de gestion de l'imperfection d'un élément d'information

Les approches de gestion des imperfections des éléments d'informations se distinguent par rapport à la nature de la distribution (probabilité, évidence et possibilité) qui permet d'accéder au contenu informationnel.

Elément d'information probabiliste : Un élément d'information est dit probabiliste si :

1. Il est exhaustif.
2. Il est exclusif.
3. Pour chaque objet O , l'information apportée par $E(O)$ ne permet pas d'obtenir une connaissance du contenu C tel que $C = E(O)$ avec une totale certitude.
4. La connaissance du contenu informationnel $C \in I_C$ associé à l'objet $O \in I_D$ est seulement accessible via une distribution des probabilités qui attribue une valeur de croyance (un taux d'occurrence ou une chance), i.e. $P\{C\}$ à chaque contenu informationnel.

Elément d'information évidentiel : Un élément d'information est dit évidentiel si :

1. Il est exhaustif.
2. Il est exclusif.
3. Pour chaque objet O , l'information apportée par $E(O)$ ne permet pas d'obtenir une connaissance du contenu C tel que $C = E(O)$ avec une totale certitude.
4. La connaissance du contenu informationnel $C \in I_C$ associé à l'objet $O \in I_D$ est seulement accessible via une distribution de masses de croyance définie sur l'ensemble des parties de I_C noté 2^{I_C} . Cette distribution de masses représente notre croyance concernant le fait que le contenu C tel que $C = E(O)$, soit dans chaque sous-ensemble de $\Theta \subseteq I_C$.

Elément d'information possibiliste : Un élément d'information est dit possibiliste s'il est :

1. Ambiguë
2. Pour chaque objet O , E associe chaque objet O à un sous-ensemble $\Theta \subseteq I_C$. La connaissance du sous-ensemble Θ associé à O est donnée par l'intermédiaire d'une distribution de possibilité définie sur 2^{I_C} .

La modélisation de l'imperfection de l'élément d'information associé à la source d'information représente une étape fondamentale pour les théories de fusion de sources d'informations. En effet, on distingue :

- La théorie des probabilités qui s'appuie sur des éléments d'informations probabilistes ;
- La théorie de l'évidence qui se focalise sur des éléments d'informations probabilistes et imprécis ;
- La théorie des ensembles flous qui se focalise sur des éléments d'informations ambiguës

La théorie des possibilités qui se focalise sur des éléments d'informations ambiguës et imprécis.

I.3 Sources d'informations

La fusion de sources d'informations prend de plus en plus d'importance avec la multiplication de ces dernières. En traitement d'images, ces sources peuvent se présenter sous forme de données issues de capteurs, d'informations à priori, de connaissances expertes, de données numériques et/ou symboliques, etc. Les sources impliquées dans un processus de fusion peuvent avoir entre elles des relations diverses : complémentarité, conflit, concordance,

discordance, etc. Chaque source d'information étant en général imparfaite, il semble souhaitable d'en combiner plusieurs afin d'avoir une « meilleure » information.

I.3.1 Exemples de sources d'informations

Nous nous limitons dans ce paragraphe à des exemples de sources d'informations utilisées dans les systèmes de fusion appliqués au traitement d'images.

Les capteurs

En télédétection, la diversité des capteurs existants conduit à la coexistence de nombreux types d'images complémentaires. Leur résolution spatiale varie entre 0.6 m et 1 km, leur résolution temporelle entre la journée et le mois. Les contraintes technologiques empêchent un capteur de fournir des images ayant à la fois de bonnes résolutions spatiale, temporelle et spectrale. Ces considérations vont à l'encontre des objectifs des utilisateurs qui nécessitent souvent l'utilisation conjointe de plusieurs types d'images. Une solution consiste à combiner (à fusionner) les différents types d'images [Boulila et al. 2007] [Ben Djebbour et al. 2001], [Ben Tabet et Maodong 2004], [Farah et al. 2008 a], [Guo et al. 2006], [Milisavljevic et Bloch 2003].

. Les connaissances expertes

L'interprétation visuelle d'images de télédétection est plus fructueuse si elle est faite par les experts du domaine. Ces experts ont des connaissances sur les espèces, l'évolution dans le temps, la structure des objets de la scène (connaissances structurelles) [Suzuki et al. 2001 a], [Suzuki et al. 2001 b]. L'intégration de cette information experte dans le processus de fusion comme nouvelle source d'information peut très probablement améliorer le résultat d'interprétation des images acquises [Guttérrez et Farinas 2004].

Les données numériques

D'autres informations de type numérique comme par exemple des inventaires antérieurs, le modèle numérique du terrain (MNT) peuvent être intégré dans le système de fusion [Petiot et Dalle 2003].

Les données symboliques

Les données symboliques peuvent être par exemple des décisions prises à la fin d'un processus de classification. Ces données peuvent être considérées comme entrées du système de fusion [Rashidi et Ghassemian 2003].

I.3.2 Modélisation des sources d'information

Nous considérerons dans la suite que nous disposons de m sources S_j avec $j \in [1, \dots, m]$. Chaque source S_j peut être caractérisée par l'information fournie par la jème source comme une fonction de l'observation x (niveau de gris par exemple pour le cas d'une source image) notée $f_j(x)$. Ces sources doivent prendre une décision sur une observation x dans un ensemble de n décisions possibles d_1, \dots, d_n . Par exemple, la décision d_i , $i \in [1, \dots, n]$, correspond au fait que l'observation vérifie une hypothèse H_i , ou encore dans le cadre de la classification l'observation appartient à la classe C_i . Chaque source fournit une information sur la décision d_i pour l'observation x que nous représenterons par $M_i^j(x)$ (j se réfère à la source et i à la décision). Ainsi la décision finale de l'expert sur l'observation x , sera prise à partir de la combinaison des informations rassemblées dans la matrice $M(x)$ donnée par (1.1) :

$$M(x) = \begin{matrix} & d_1 & \cdots & d_i & \cdots & d_n \\ \begin{matrix} S_1 \\ \vdots \\ S_j \\ \vdots \\ S_m \end{matrix} & \begin{bmatrix} M_1^1(x) & \cdots & M_i^1(x) & \cdots & M_n^1(x) \\ \vdots & \ddots & \vdots & \ddots & \vdots \\ M_1^j(x) & \cdots & M_i^j(x) & \cdots & M_n^j(x) \\ \vdots & \ddots & \vdots & \ddots & \vdots \\ M_1^m(x) & \cdots & M_i^m(x) & \cdots & M_n^m(x) \end{bmatrix} \end{matrix} \quad (1.1)$$

I.3.3 Types de sources et relations entre sources

Sources concordantes et sources discordantes

Deux sources sont dites concordantes (ou encore conjonctives) si les informations données par les deux sources sont compatibles (vont dans le même sens). Leur fusion améliore à priori la qualité des décisions. En revanche, deux sources sont dites discordantes (disjonctives ou conflictuelles) si les informations données par ces sources sont incompatibles et leur fusion peut dégrader la qualité du résultat (en général en terme de précision).

Sources redondantes et sources complémentaires

Les sources redondantes apportent la même information et sont définies sur le même espace de discernement (ou de définition). Cette redondance peut être utile pour la réduction des incertitudes et des imprécisions. Les sources complémentaires sont définies sur des espaces de définition différents et sont exploitées directement dans le processus de fusion pour avoir une information globale plus complète et pour lever les ambiguïtés.

I.3.4 Typologie de la fusion d'informations

Niveaux de fusion

On a pu recenser dans la littérature trois niveaux de fusion :

- Fusion bas niveau : Il s'agit de combinaisons opérant sur les données brutes issues de différentes sources. C'est le cas des méthodes de fusion en traitement d'images basées sur un traitement local (coté pixel).
- Fusion de niveau intermédiaire où les données sont de "type primitives ou attributs". C'est le cas des méthodes de fusion opérant sur des objets, des régions ou des structures préalablement extraites.
- Fusion de niveau symbolique : il s'agit de la fusion de décisions (fusion de classifieurs par exemple).

Types de fusion

Le type de fusion dépend du type des informations à fusionner :

- Fusion numérique : C'est le cas où l'information est quantifiable (exemple : niveau de gris, altitude, etc.)
- Fusion symbolique : Il s'agit de construire la source symbolique représentant la connaissance des experts. Ces connaissances sont souvent représentées sous forme de règles. Dans un problème de classification par exemple, il s'agit d'intégrer la connaissance des experts sur les classes recherchées à travers des règles concernant des propriétés topologiques, morphologiques, des relations spatiales entre régions, etc.

I.4 Formalismes de fusion de sources d'informations

L'utilisation de plusieurs sources permet, grâce à la complémentarité et à la redondance des informations disponibles, de faire face à l'imperfection de ces sources. Pour cela, le modèle choisi devra s'adapter aux spécificités des données. Les principaux modèles de fusion sont les modèles probabilistes, possibilistes et évidentiels [Bloch 2003a]. Les distributions de probabilité permettent de représenter, en langage mathématique, une information relative à une grandeur dont la valeur dépend du hasard (variabilité aléatoire). Les distributions de possibilité permettent de représenter une information qui est incomplète et/ou imprécise (avis d'expert). Elles enrichissent la notion de simple intervalle par l'expression de préférences au sein de celui-ci. Les fonctions de croyance assignent des masses de probabilités sur des ensembles quelconques ce qui fournit un mode d'analyse et de traitement des données présentant à la fois un caractère aléatoire et un caractère imprécis.

Nous présentons dans ce qui suit les notations que nous adoptons pour la formalisation du

problème de fusion de sources d'information. Soient :

- $\Omega = \{H_1, \dots, H_n\}$: le cadre de discernement composé de n hypothèses (exclusives et exhaustives)
- 2^Ω : le référentiel de définition. C'est l'ensemble des parties de Ω ($2^\Omega = \{A | A \subseteq \Omega\}$, ce sont donc des ensembles nets) ;
- A_i : Les éléments (événements) de 2^Ω avec $i \in [1, \dots, |2^\Omega|]$

Considérons un problème général de fusion de sources d'informations. Soit x l'élément sur lequel porte la décision et $f_j(x)$ l'information associée à x fournie par la source S_j , $j \in \{1, \dots, m\}$.

I.4.1 Fusion probabiliste

La fusion probabiliste suit trois étapes fondamentales à savoir : la représentation des incertitudes souvent par une distribution Gaussienne, l'opération de combinaison par l'application du théorème de Bayes (ou d'opérateurs), et le suivi d'états évolutifs par le mécanisme de Prédiction/Estimation.

I.4.1.1 Modélisation par les distributions de probabilités

L'étape de modélisation concerne le passage d'informations extraites des différentes sources à une représentation mathématique liée à la théorie des probabilités. Les distributions de probabilités sont utilisées pour modéliser l'imprécision sur les mesures et l'incertitude sur les hypothèses.

La distribution Gaussienne, ou normale

- *Modélisation de l'imprécision sur les mesures :*

Il s'agit d'attribuer une distribution gaussienne aux erreurs. Supposons que l'on dispose de n observations \mathcal{G}_i de la valeur avec $i \in [1, \dots, n]$. On cherche à connaître la valeur x_{vrai} . Alors $\mathcal{G}_i = x_{vrai} + e_i$ où e_i est l'erreur inconnue faite lors de la mesure \mathcal{G}_i . Si l'on attribue une distribution gaussienne $p(x_i / x_{vrai})$ à ces erreurs, alors on a l'équation (1.2) suivante :

$$p(\mathcal{G}_i / x_{vrai}) = \left(\frac{1}{2\pi\sigma^2} \right)^{n/2} \exp - \frac{1}{2} \left[\frac{(\mathcal{G}_i - \hat{x})}{\sigma} \right]^2 \quad (1.2)$$

$$\text{Avec } \hat{x} = \frac{1}{n} \sum_n \mathcal{G}_i$$

$$\text{et } \sigma^2 = \frac{1}{n} \sum_n (\mathcal{G}_i - \hat{x})^2$$

- *Modélisation de l'incertitude sur les hypothèses :*

Il s'agit de modéliser l'incertitude d'une source (capteur par exemple) connaissant la distribution gaussienne représentant la distribution de probabilité des erreurs de mesures : la valeur estimée \hat{x} de la grandeur x est égal à \mathcal{G} , et l'imprécision est estimée à σ selon l'équation (1.3) suivante.

$$p(x/\mathcal{G}) = \left(\frac{1}{2\pi\sigma^2} \right)^{1/2} \exp -\frac{1}{2} \left[\frac{(x-\mathcal{G})}{\sigma} \right]^2 \quad (1.3)$$

L'inférence Bayésienne

On appelle **inférence bayésienne** la démarche logique permettant de calculer ou réviser la probabilité d'une hypothèse. Cette démarche est régie par l'utilisation de règles strictes de combinaison des probabilités, desquelles dérive le théorème de Bayes. Dans la perspective bayésienne, une probabilité n'est pas interprétée comme le passage à la limite d'une fréquence, mais plutôt comme la traduction numérique d'un état de connaissance

La théorie des probabilités est exploitée en fusion de sources d'informations souvent associée à la théorie bayésienne de la décision. L'information y est modélisée par une probabilité conditionnelle (par exemple la probabilité pour qu'un pixel appartienne à une classe particulière, étant donnée les sources images disponibles). Ce qui peut être écrit selon les notations du paragraphe I.3.2 comme $M_i^j = P(d_i | f_j)$ ou encore pour un problème de classification particulier $M_i^j(x) = p(x \in C_i | f_j(x))$.

La distribution de probabilité $P(\cdot / f_j)$, pour chaque hypothèse H_i correspondant à d_i (la décision d_i correspond au fait que l'observation vérifie une hypothèse H_i) selon la source d'information S_j considérée, peut être décrite par l'application correspondant à (1.4):

$$P(\cdot / f_j): \begin{array}{l} \Omega \rightarrow [0,1] \\ H_i \rightarrow p(H_i / f_j) \end{array} \quad (1.4)$$

L'étape de modélisation est ainsi fondée sur les probabilités conditionnelles. Dans cette approche probabiliste, nous sommes forcés d'avoir des décisions exclusives et exhaustives. Dans le cas de la classification, ceci signifie que si $x \in C_i$ alors $x \notin C_k, \forall k \neq i$ et que toutes les classes sont connues d'avance (hypothèse du monde fermé).

I.4.1.2 Estimation des probabilités

Pour l'estimation de ces distributions de probabilités, deux cas se présentent : un cas discret et un cas continu. L'estimation dans le cas discret s'est généralement effectuée par l'application de la formule de Bayes, ce qui revient à estimer $P(f_j | H_i)$ par dénombrement i.e. à l'aide des fréquences sur une base d'apprentissage. Les distributions $P(H_i / f_j)$ sont

rarement connues en traitement de signal et des images, d'où les probabilités conditionnelles $P(f_j(x)|x \in C_i)$ sont apprises par dénombrement sur des zones de test.

Dans le cas continu, il faut chercher à approcher les distributions $P(H_i / f_j)$ par des distributions connues. Les distributions gaussiennes sont très couramment employées. Une pratique courante dans la fusion de sources d'informations issues de capteurs est de modéliser les mesures par des gaussiennes (calibrés sur l'intervalle d'erreur : estimation des moyennes et variances).

La méthode bayésienne appliquée pour l'agrégation de l'avis de plusieurs experts suppose que l'analyste qui recueille les opinions des experts possède lui-même une opinion sur la valeur du paramètre x . Cette opinion étant représentée par une distribution de probabilité. Les valeurs précises fournies par les experts sont alors utilisées pour mettre à jour l'opinion de l'analyste. La fiabilité des experts est capturée à l'aide de fonctions de vraisemblance, à savoir les probabilités conditionnelles $P_i(x_i|x_{vrai})$ pour que l'expert E_i fournisse la valeur $x = x_i$ sachant que la vraie valeur de x est x_{vrai} . Connaissant $P(x)$ et $P_i(x_i|x)$ on peut appliquer le théorème de Bayes pour calculer la probabilité à postériori. Si les experts ne sont pas indépendants, on utilise directement une distribution joint $P(x_1 \cdots x_n|x)$ au travers de coefficients de corrélation.

1.4.1.3 Combinaison

La théorie des probabilités propose une méthode de combinaison. L'opération de combinaison se fait par l'application du théorème de Bayes. Cette combinaison se décline, bien sûr dans le cas continu comme dans le cas discret.

Combinaison bayésienne

Il s'agit d'évaluer les chances de toute proposition en calculant sa probabilité d'être vraie, conditionnée par l'information disponible à travers les différentes sources [Martin 2005]. En effet, le théorème de Bayes dans le cas discret s'exprime (pour des sources S_j indépendantes), de la façon décrite par l'équation (1.5) :

$$P(H_i / f_1, \dots, f_m) = \frac{P(H_i) \cdot \prod_j p(f_j / H_i)}{\sum_{H_k} (P(H_k) \cdot \prod_j p(f_j / H_k))} \quad (1.5)$$

Où $P(f_j / H_i)$ est la probabilité conditionnelle modélisant l'incertitude sur les mesures (la probabilité d'avoir la mesure sachant que l'hypothèse H_i est vraie) et $P(H_i)$ la probabilité à priori sur l'hypothèse .

Autres combinaisons

Certains auteurs ont utilisé des opérateurs de combinaison tels que le maximum, le

minimum, la moyenne, la médiane, etc. [Bloch 1996a], [Florea 2007].

1.4.1.4 Décision

Pour cette dernière étape du processus de fusion probabiliste, de nombreux critères de décision sont envisageables. La règle la plus employée est celle du maximum a posteriori (1.6):

$$p(H_k | f_1, \dots, f_m) = \max_{i \in \{1, \dots, n\}} p(H_i | f_1, \dots, f_m) \quad (1.6)$$

Nombreux critères statistiques ont été utilisés pour la prise de décision tels que l'espérance maximale, le maximum de vraisemblance (cas particulier de l'espérance maximale), le maximum d'entropie, le critère minimax...etc. [Bloch 2003a].

1.4.1.5 Applications

Les méthodes probabilistes se divisent en méthodes objectives (fréquentiste) et subjectives. Dans les approches fréquentistes (ou objectivistes) la notion de probabilité est reliée très souvent à l'observation de phénomènes physiques, à leurs répétition dans des séquences longues, alors que les approches subjectivistes considèrent les probabilités comme des mesures de confiance. Dans ces dernières (subjectivistes), les hypothèses sont évaluées en fonction de données observées et de probabilités a priori, même si la connaissance est incomplète. Le choix d'une approche peut être raisonné et justifié par le problème posé et l'interprétation que l'on souhaite donner aux probabilités.

Sous l'hypothèse forte et rarement vérifiée que l'information d'une source en fonction des différentes décisions possibles peut s'exprimer sous la forme de distributions de probabilités, la méthode bayésienne est optimale.

Le choix du formalisme probabiliste pour la fusion d'informations a régressé et a été remplacé dans plusieurs travaux par les probabilités imprécises (probabilités inférieurs et supérieurs) [Duong 2005] ou par les possibilités [Dubois et Prade 1994].

Limites

Les méthodes probabilistes sont objet de critiques. Le problème majeur des probabilités est qu'elles représentent essentiellement l'incertitude et très mal l'imprécision, ceci entraîne souvent une confusion des deux notions. En effet, si elles représentent bien l'incertain qui entache l'information, elles ne permettent pas aisément de représenter son imprécision. Ensuite, elles nécessitent que, lors de l'apprentissage, des contraintes très strictes soient vérifiées par les mesures (imposées par les axiomes de base des probabilités) et par l'ensemble de classes considéré (exhaustivité).

Ces contraintes peuvent rendre l'apprentissage très délicat, ou, si le problème à traiter est complexe, conduire pratiquement à des incohérences car l'utilisateur ne peut alors prendre en compte tout le réseau des dépendances probabilistes. L'apprentissage de lois de probabilités nécessite, outre les hypothèses, un nombre important de données. L'étape d'estimation est soumise à des difficultés telles que la difficulté du calcul des probabilités a priori dans de nombreux problèmes [Bloch 2005].

La combinaison est également contrainte par les axiomes des probabilités et son utilisation pratique nécessite souvent l'hypothèse d'indépendance. D'autre part, au niveau de la fusion, cette théorie présente une difficulté pour modéliser le comportement de sources dépendantes et l'absence de gestion du conflit entre sources d'information.

Intérêts

L'avantage essentiel des méthodes probabilistes vient du fait qu'elles reposent sur une base mathématique solide et ont été l'objet de nombreux travaux. Elles proposent donc un éventail d'outils très riche permettant aussi bien la modélisation que l'apprentissage des modèles. Elles proposent également des règles d'usage soit théoriques soit heuristiques. Enfin, la modélisation probabiliste est actuellement un concept universellement partagé qui sert naturellement de base de comparaison aux autres modélisations.

I.4.2 Fusion possibiliste

La théorie des possibilités formulée par Zadeh à la fin des années 70 est issue du concept des sous-ensembles flous développés également par Zadeh. Elle a été essentiellement développée en France par Dubois et Prade [Dubois et Prade 1994]. Elle repose sur les mesures de possibilité et de nécessité qui permettent de décrire l'incertitude d'un événement par le degré de possibilité et le degré de possibilité de l'évènement contraire qui s'interprète comme un degré de nécessité (dans le sens de la certitude).

Avant d'introduire les notions de la théorie des possibilités, nous sommes amenés à introduire quelques notions de la logique floue.

I.4.2.1 Logique floue

Les connaissances imprécises ou vagues n'ont été prises en considération qu'à partir de 1965 lorsque L.A.Zadeh a introduit la notion d'ensemble «flou». Il s'agit de représenter la granularité dans le passage d'une situation à une autre et de modéliser l'appartenance partielle à une classe à limites mal définies. La notion de sous-ensembles flous a pour but de permettre des gradations dans l'appartenance d'un élément à une classe, c'est-à-dire d'autoriser un élément à appartenir plus ou moins à une classe prédéfinie. Ceci évite l'utilisation arbitraire de limites rigides de classes et répond au besoin de présenter des connaissances imprécises, soit parce qu'elles sont exprimées en langage naturel, soit parce qu'elles sont obtenues avec des

instruments d'observations qui produisent des erreurs de mesure [Mascarilla et al. 1993] [Roux1994] [Suzuki et al. 2001 a]. On parle souvent d'ensemble flou à la place de sous-ensemble flou, et ce par abus de langage conformément à la traduction du terme original anglais « fuzzy set ».

Ainsi, la théorie des ensembles flous est une généralisation de la théorie classique des ensembles admettant des situations intermédiaires entre le tout et le rien et permettant de manipuler des connaissances imparfaitement décrites (telles que des données décrites symboliquement i.e. avec des mots), vagues ou imprécises.

1.4.2.2 Notion de sous-ensemble flou

Un ensemble classique ou net est composé d'éléments qui satisfont à des propriétés précises. Ainsi des éléments qui ne satisfont pas ces propriétés n'appartiennent pas à cet ensemble. Notons Ω , un ensemble net et x un élément de Ω . Un sous-ensemble A de Ω peut s'écrire à partir de sa fonction caractéristique $\chi_A : \Omega \rightarrow \{0,1\}$ comme indiqué dans (1.7):

$$\chi_A(x) = \begin{cases} 1 & \text{si } x \in A \\ 0 & \text{si } x \notin A \end{cases} \quad (1.7)$$

C'est une fonction binaire qui vérifie l'appartenance d'un point x de Ω à A . La théorie des sous-ensembles flous propose une fonction d'appartenance qui vérifie l'appartenance graduelle. Ainsi la fonction caractéristique est une fonction d'appartenance particulière.

Définition : Un sous-ensemble flou F de Ω est défini par une fonction d'appartenance $\mu_F(x)$ qui à tout x de Ω associe une valeur réelle $\mu_F(x)$ dans $[0,1]$ représentant le degré d'appartenance de x au sous-ensemble flou F .

1.4.2.3 Fonctions d'appartenance

Parmi les techniques non probabilistes qui ont fait leur apparition depuis une quinzaine d'années en fusion, la théorie des ensembles flous qui fournit un très bon outil pour représenter explicitement des informations imprécises, sous la forme de fonctions d'appartenance. La mesure $M_i^j(x)$ introduite dans (I.3.2) s'écrit alors sous la forme : $M_i^j(x) = \mu_i^j(x)$.

Les fonctions d'appartenance décrivent le degré d'appartenance partielle d'un individu à une classe et n'associent pas de bornes strictes. Le degré d'appartenance d'un individu x à une classe H_i est généralement noté $\mu_{H_i}(x)$ (de même si x est membre d'un sous-ensemble flou A , le degré d'appartenance de x à A est noté $\mu_A(x)$). La fonction d'appartenance est alors illustrée par (1.8) :

$$\mu_{H_i} : \begin{cases} I_D \rightarrow [0,1] \\ x \rightarrow \mu_{H_i}(x) \end{cases} \quad (1.8)$$

I.4.2.4 Modélisation par les distributions de possibilités

La théorie des possibilités constitue un cadre permettant de traiter des concepts d'incertitude de nature non probabiliste. Lorsqu'elle est considérée à partir de la notion d'ensemble flou, la théorie des possibilités constitue un cadre permettant d'exploiter, dans un même formalisme, les imprécisions et les incertitudes [Masson 2005].

La modélisation possibiliste se base sur la théorie des possibilités. Cette théorie est beaucoup plus récente que la théorie des probabilités. Elle est assez souvent utilisée dans les approches d'implémentation pour lesquelles la connaissance à priori est de nature experte, contrairement à la théorie des probabilités qui est mieux adaptée à la connaissance statistique [Roux 1994].

I.4.2.5 Fonctions de décision dans la théorie des possibilités

Une mesure de possibilité est une fonction Π de 2^Ω dans $[0,1]$ qui vérifie les équations du système (1.9) :

$$\left\{ \begin{array}{l} \Pi(\emptyset) = 0 \text{ et } \Pi(\Omega) = 1 \\ \forall I \in \mathcal{N}, \forall A_i \subseteq \Omega, i \in I, \Pi(\cup_{i \in I} A_i) = \sup_{i \in I} \Pi(A_i) \end{array} \right. \quad (1.9)$$

Ainsi, dans le cas fini, une mesure de possibilité est une mesure floue. Plus la valeur de la possibilité d'un évènement est proche de 1, plus la réalisation de cet évènement est possible. Si la possibilité d'un évènement est nulle, cela signifie que cet évènement est impossible.

Pour lever l'indétermination sur la réalisation ou non de A , une information supplémentaire sur la possibilité de l'évènement contraire est ajoutée. Les mesures de nécessité, mesures duales des mesures de possibilité, sont introduites dans cet objectif. La nécessité d'un évènement est définie comme la mesure de l'impossibilité de l'évènement contraire.

Une mesure de nécessité est une fonction N de $\text{Parties}(\Omega)$ (l'ensemble des parties de Ω , ce sont donc des ensembles nets) dans $[0,1]$ telle que (1.9):

$$\left\{ \begin{array}{l} N(\emptyset) = 0 \text{ et } N(\Omega) = 1 \\ \forall I \in \mathcal{N}, \forall A_i \subseteq \Omega, i \in I, N(\cup_{i \in I} A_i) = \inf_{i \in I} N(A_i) \end{array} \right. \quad (1.10)$$

Cette définition est équivalente à la relation reliant nécessité et possibilité décrite par l'équation (1.11) suivante :

$$\forall A \subseteq \Omega, N(A) = 1 - \Pi(\bar{A}) \quad (1.11)$$

La valeur prise par la mesure de nécessité pour un évènement A indique le degré de certitude avec lequel cet évènement sera réalisé. Plus ce degré est proche de 1, plus il est certain que cet évènement sera réalisé. Ainsi l'incertitude d'un évènement est décrite par deux valeurs : le degré de possibilité et le degré de nécessité.

Distributions de possibilité

Les distributions de possibilité permettent d'attribuer un degré de possibilité à tout élément de Ω , et non plus de 2^Ω .

Définition : Une distribution de possibilité est une fonction π de Ω dans $[0,1]$ vérifiant la propriété de normalisation décrite par : $\sup_{x \in \Omega} \pi(x) = 1$.

La relation entre les deux expressions floues et possibilistes est exprimée par l'équation suivante (1.12) :

$$\Pi^x(H_i) = \mu_{H_i}(x) \quad (1.12)$$

I.4.2.6 Combinaison

Cette théorie des possibilités offre plusieurs opérateurs de combinaison [Bloch 1996a] qui dépendent de la relation entre les sources utilisées dans l'application :

- \wedge : l'opérateur d'intersection ensembliste T-norme (ou opérateur conjonctif) pour la combinaison entre sources concordantes $\Pi^{S_1, S_2}(H_i)$, comme illustrés dans les deux exemples (1.13):

$$\min(\Pi^{S_1}(H_i), \Pi^{S_2}(H_i)) \quad \text{et} \quad \Pi^{S_1}(H_i) \times \Pi^{S_2}(H_i) \quad (1.13)$$

- \vee : l'opérateur d'union ensembliste T-conorme (opérateur disjonctif) pour la combinaison entre sources discordantes, en voici deux exemples (1.14) :

$$\max(\Pi^{S_1}(H_i), \Pi^{S_2}(H_i)) \quad \text{et} \quad \Pi^{S_1}(H_i) + \Pi^{S_2}(H_i) \quad (1.14)$$

- Les opérateurs adaptatifs utilisés dans le cas de sources qui ne sont pas totalement fiables et permettent de calculer un degré de conflit $h(\Pi^{S_1}, \Pi^{S_2})$ entre deux sources, par exemple dans cette hypothèse d'opérateurs on obtient l'équation (1.15):

$$h(\Pi^{S_1}, \Pi^{S_2}) = \max_H(\min(\Pi^{S_1}, \Pi^{S_2})) \quad (1.15)$$

Si $h(\Pi^{S_1}, \Pi^{S_2}) = 0$, alors les sources sont complètement discordantes : $\Pi^{S_1, S_2} = \Pi^{S_1} \vee \Pi^{S_2}$

Si $h(\Pi^{S_1}, \Pi^{S_2}) = 1$, alors les sources sont complètement concordantes : $\Pi^{S_1, S_2} = \Pi^{S_1} \wedge \Pi^{S_2}$

1.4.2.7 Applications

Nous présentons ici de manière non exhaustive quelques domaines d'application où la fusion d'information est réalisée à partir de méthodes issues de la théorie des sous-ensembles flous et de la théorie des possibilités.

- En robotique : la théorie des possibilités est utilisée pour la localisation de robots à l'aide de capteurs à infra rouge et odométrique .
- En traitement d'images : Nous citons des applications telles que la reconnaissance de partitions musicales à partir d'images optiques afin d'automatiser l'archivage, la reconnaissance d'images médicales 3D du cerveau pour la détection d'anomalies, la classification d'images satellites, la vision multi-caméras, la restauration d'images à partir d'intégrales floues, reconnaissance de locuteurs à partir de signal sonore, segmentation floue à partir d'une représentation symbolique de la luminance et des nuances, la fusion étant réalisée à partir de règles heuristiques. La théorie des possibilités est retenue pour la reconnaissance d'objet dans des images sonar.
- En classification : Nous citons la classification d'objets sous-marins, de comportements ou de données radar (où l'intégrale de Sugeno et différentes combinaisons (conjonctives et disjonctives) sont dans ce dernier cas comparés.

Limites

Les limites de la théorie des possibilités se résument par la difficulté du choix du mode de combinaison le mieux adapté aux données.

Intérêts

Cette théorie des possibilités est dotée d'une modélisation de la connaissance facilitant le

calcul (fonctions de distribution : trapèze ou triangulaires). Elle gère également la méconnaissance et gère le conflit par des règles adaptatives.

L'intérêt des sous-ensembles flous pour le traitement de l'information en image et vision peut se décliner en particulier selon les quatre aspects suivants :

- la capacité des sous-ensembles flous à représenter l'information spatiale dans les images ainsi que son imprécision, à différents niveaux (local, régional ou global), et sous différentes formes (numérique, symbolique, quantitative, qualitative) ;
- la possibilité de représenter des informations très hétérogènes, extraites directement des images ou issues de connaissances externes, comme des connaissances expertes ou génériques sur un domaine ou un problème ;
- la possibilité de généraliser des opérations aux sous-ensembles flous pour manipuler l'information spatiale, la souplesse des opérateurs de combinaison permettant de fusionner des informations de multiples natures dans des situations très variées.

I.4.3 Fusion dans la théorie des fonctions de croyance

La théorie des fonctions de croyances permet de représenter à la fois l'imprécision et l'incertitude à travers deux fonctions de crédibilité et de plausibilité dérivées des fonctions de masse d'évidence [Bloch 2005], [Burrus 2003], [Desachy et al. 2000], [Vannoorenberghe 2003]. Le principe de cette théorie repose sur la manipulation de fonctions de masse d'évidence définies sur des sous-ensembles et non sur des singletons comme dans la théorie de probabilités [Denoeux 2004], [Denoeux 2005].

La théorie de Dempster-Shafer (TDS) a été à la base de la théorie des fonctions de croyance et traite le cas où les hypothèses élémentaires de l'ensemble de définition sont exhaustives et exclusives [Janez 1996], [Desachy et al. 1996], [Desachy et al. 2000].

I.4.3.1 Modélisation par les fonctions de masses d'évidence

La mise en œuvre de la théorie pour une application spécifique en traitement de l'information requiert plusieurs étapes de modélisation.

La première consiste à définir le cadre de discernement Ω qui dépend de l'application envisagée. Celui-ci peut correspondre aux régions à discerner pour la segmentation d'images et aux classes pour les problèmes de discrimination. Cette étape est généralement établie de manière supervisée par un expert bien que certains auteurs utilisent des algorithmes de classification non supervisée. La deuxième étape est celle de l'estimation des fonctions de masses.

Dans la TDS, les fonctions de masses sont définies sur tous les sous-espaces de l'ensemble des disjonctions noté 2^Ω du cadre de discernement à valeurs dans $[0,1]$. La distribution de masses est définie ainsi (1.16):

$$m : 2^\Omega \rightarrow [0,1] \quad \left| \quad \text{et vérifie} \quad \left| \begin{array}{l} m(\phi) = 0 \\ \sum_{A \in 2^\Omega} m(A) = 1 \\ m(\Omega) = 1 \end{array} \right. \right. \quad (1.16)$$

$m(A)$, appelée masse de A est la confiance portée strictement dans A sans que celle-ci puisse être répartie sur les hypothèses singletons qui la composent. On appelle éléments focaux les éléments de 2^Ω de masses non nulles.

Une proposition $B \in 2^\Omega$, par exemple $B = \{H_1, H_3\}$, représente explicitement le doute entre les hypothèses composant B , mais la masse de croyance $m(B)$ allouée à B ne donne aucune information sur les hypothèses et sous-ensembles composant B . Cette caractéristique provient de la nature non-additive des fonctions de masse et représente une différence fondamentale avec la théorie des probabilités où la mesure utilisée est additive.

Si la source est parfaite, l'information est précise et sûre, il existe donc une hypothèse singleton C_i unique tels que $m(\{C_i\}) = 1$.

I.4.3.2 Estimation des fonctions de masse d'évidence

La modélisation des fonctions de masse est un problème crucial et il n'y a pas, à notre connaissance, de méthode universelle. Il s'agit de choisir avec soin les éléments focaux pour obtenir une modélisation riche et flexible capable d'appréhender une large gamme de situations. On trouve essentiellement dans la littérature des méthodes heuristiques. Quelques méthodes calculent d'abord les masses sur les singletons puis répartissent ensuite le reste de la croyance sur certains sous-ensembles dans une démarche simplificatrice.

Dans la théorie des croyances, la première difficulté est le choix de la fonction de masse. Evidemment, selon la nature et la provenance des informations impliquées dans le système de fusion, les modèles à mettre en œuvre penchent vers des fonctions de masses appropriées [Dempster 2008], [Le Hégarat-Masclé et al. 2003], [Malpica et al. 2007], [Provan 1989], [Rashidi et Ghassemian 2003], [Rombaut et Zhu 2002], [Shafer et Legan 1987].

Dans le chapitre IV, nous présentons un éventail des approches existantes d'estimation des fonctions de masse. Nous proposons ensuite dans le chapitre V, une approche de modélisation et d'estimation des fonctions de masses prenant en considération la nature des sources d'informations impliquées dans notre système de fusion ainsi que les caractéristiques de la scène d'étude. Cette approche permet aussi de proposer des solutions permettant de réduire la complexité des calculs des masses et de leurs combinaisons.

I.4.3.3 Décision

La théorie des fonctions de croyances offre plusieurs règles de décisions fondées sur la maximisation d'un critère. La TDS emploie le maximum des fonctions de crédibilité ou des fonctions de plausibilité rappelées ci-dessous. Si les premières (fonctions de crédibilité)

peuvent être trop pessimistes, les secondes (fonctions de plausibilité) peuvent être trop optimistes.

Maximum de croyance

La crédibilité de $A \in 2^\Omega$, notée $Cr(A)$, est la croyance que la vérité est dans A . C'est défini par la somme des masses des propositions incluses dans A . D'où les équations (1.17) suivantes :

$$Cr(A) = \sum_{B \subseteq A} m(B) \text{ et } \begin{cases} Cr(\Omega) = 1 \\ Cr(\Phi) = 0 \\ \sum_{A \in 2^\Omega} Cr(A) \geq 1 \end{cases} \quad (1.17)$$

Maximum de plausibilité

$Pl(A)$ dénote la plausibilité que la vérité est dans A . C'est aussi la somme des masses des propositions dont l'intersection avec A est non nulle. D'où l'équation (1.18) :

$$Pl(A) = \sum_{A \cap B \neq \phi} m(B) \quad (1.18)$$

Les fonctions $Pl(A)$ et $Cr(\bar{A})$ sont liées par la relation : $Pl(A) + Cr(\bar{A}) = 1$.

1.4.3.4 Combinaison par l'opérateur orthogonal de Dempster

Dans la plupart des applications en fusion de sources d'information, on cherche à obtenir une fonction de masse combinée, plus focalisée que les fonctions de masse initiales prises séparément pour chaque source. Ainsi, on préfère souvent la fusion conjonctive, ce qui induit la prise en compte les imprécisions, fiabilités, ambiguïtés de chaque source à l'étape de modélisation. Elle constitue alors l'étape la plus cruciale et qui requiert le plus d'attention [Sentz et Ferson 2002]. L'étape de fusion (ou combinaison) met en évidence les relations entre les sources combinées.

La TDS offre une possibilité de combinaison entre les différentes sources en utilisant la règle proposée par Dempster appelée aussi somme orthogonale. Cette combinaison a pour effet d'affecter la masse à des propositions dont le nombre d'éléments est plus faible que celui des propositions initiales.

Pour deux sources S_1 et S_2 , on écrit la combinaison orthogonale \oplus , sous la forme non normalisée $m = m^{S_1} \oplus m^{S_2}$, qui s'écrit pour un évènement A comme (1.19):

$$m(A) = \sum_{B \cap C = A} m^{S_1}(B) \times m^{S_2}(C) \quad (1.19)$$

I.4.3.5 Modélisation du conflit

Le conflit entre sources noté K est modélisé par l'équation (1.20):

$$K = m(\phi) = \sum_{B \cap C = \phi} m^{S_1}(B) \times m^{S_2}(C) \quad (1.20)$$

Dempster-Shafer préconise de normaliser la distribution de masses obtenue après combinaison, d'où l'équation de la combinaison normalisée suivante (1.21):

$$m(A) = \frac{1}{1-K} \sum_{B \cap C = A} m^{S_1}(B) \times m^{S_2}(C) \quad , \quad K \neq 1 \quad (1.21)$$

La distribution m correspond alors aux critères définis dans la formule (1.17).

I.4.3.6 Applications

Le cadre théorique de la TDS, ou plus généralement des fonctions de croyance, est suffisamment souple pour être appliqué dans de nombreux domaines applicatifs des sciences et technologies de l'information et de la communication tels que l'analyse de données, le diagnostic, l'aide à la décision, la perception multi capteurs et le traitement d'images.

Classification

La classification est sans doute l'application la plus étudiée avec tout type de données dans le cadre de cette théorie. T. Denoeux s'intéresse dans [Denoeux 2004], [Denoeux 2005] à un ensemble d'applications de la théorie des fonctions de croyance pour la classification à travers la construction de classifieurs crédibilistes. Les conclusions tirées de [Denoeux 2004], [Denoeux 2005] se résument dans le fait que le formalisme des fonctions de croyance permet d'exploiter en apprentissage une information incertaine et imprécise (étiquetage imprécis par exemple) et de traduire le résultat d'une analyse statistique des données sous forme incertaine et imprécise [Naceur et al. 2000] [Régis et al. 2007] [Farah 2008 et al. b].

Système d'information géographique

J.A. Malpica et al. dans [Malpica et al. 2007] présentent un aperçu de l'utilisation de la théorie de Dempster-Shafer dans les systèmes d'information géographiques (SIG) et montrent des exemples d'utilisation de la TDS pour la résolution de problèmes concernant la prévention des risques, les inventaires de ressources naturelles, l'exploration minière, la cartographie, la géologie et la planification d'interventions. Toutes ces applications se basent au départ sur une

étape de classification qui est importante, parce qu'elle représente la première étape dans l'abstraction ou la réduction d'information dans un SIG. Cette étude a montré que les résultats obtenus avec TDS peuvent être considérés comme concurrentes avec les autres approches souvent utilisées pour des applications tels que les réseaux de neurones, la théorie d'approbation et la théorie des probabilités, bayésienne en particulier. Ainsi, TDS est une théorie qui a été appliquée à la science géographique avec un certain succès. Le problème principal dans les applications est l'estimation de la croyance et de l'incertitude aux données. Cependant, peu d'études ont présentées des comparaisons avec d'autres méthodes d'application de la TDS aux SIG.

Applications d'imagerie médicale : diagnostic

I.Bloch et E.Maitre montrent dans [Bloch et maitre 2004] l'intérêt de la théorie des fonctions de croyance dans les applications de fusion d'images pour la classification, la segmentation ou la reconnaissance, et les avantages par rapport aux approches classiques probabilistes et bayésiennes. Le document illustre une grande flexibilité des modélisations possibles, prenant en compte à la fois l'incertitude et l'imprécision, l'ignorance partielle ou globale, la fiabilité des sources, la capacité de chaque source à fournir des informations fiables ou non sur chaque classe, des informations à priori qui ne sont pas forcément représentables par des probabilités, etc. L'illustration est faite sur un cas d'application de diagnostic médical pour la mise en évidence de zones de volume partiel. La décision a été prise en faveur d'une hypothèse composée s'adaptant au mode de raisonnement du médecin [Bloch 1996 b].

Reconnaissance du visage et des expressions faciales

Un ensemble de travaux sur la reconnaissance du visage et des expressions faciales a été effectué par un ensemble de chercheurs dont nous citons en France les travaux de Z. Hammal, M. Rombaut, A. Caplier, L. Couvreur et Y.M Zhu et dans [Hammal et al. 2004], [Hammal et al. 2007].

Traitement d'Images

Le traitement d'images telles que satellitaires [Nedelec et al. 2003], optiques (segmentation, fusion de pixels), ont fait l'objet de plusieurs travaux de recherche ainsi que les images sonar haute fréquence (caractérisation de sédiments) et basse fréquence (détection de mines enfouies) et davantage les images radar [Jouan et Allard 2004] et [Martin et Osswald 2007].

Suivi de cibles et localisation

La théorie des fonctions de croyance a aussi été utilisée pour le suivi de cibles et la

localisation d'objets. Citons à titre d'exemple le travail de C.Royère et al. [Royère et al. 2003] qui consiste en l'élaboration de fonctions de croyance à partir de données GPS (—Global Positioning System—en anglais pour —système de positionnement mondial—en français) et SIG pour la localisation d'un véhicule et celui de F. Caron et al. [Caron et al. 2007] qui montre l'intérêt de la modélisation de mesures de proximité par la théorie des fonctions de croyance pour une application de localisation de matériaux de construction équipés d'étiquettes RFID (en anglais —Radio Frequency Identification—pour —Identification de fréquences radio—en français). Pour ce deuxième cas par exemple, la théorie des fonctions de croyance est un cadre théorique permettant la modélisation de l'imperfection de l'information. En effet, l'information issue du lecteur recevant le signal d'une étiquette est imprécise puisqu'elle informe seulement sur la région dans laquelle se trouve l'étiquette, sans connaître sa position exacte. De plus, cette information est incertaine car la zone de communication d'une étiquette est anisotrope et dépend du temps et de son environnement et donc la position du lecteur, repérée par GPS est incertaine (bruitée) car il peut exister des objets entre l'étiquette et le lecteur impliquant un blocage du signal.

I.4.3.7 Réflexions

Intérêt

Une modélisation fine adaptée au problème est possible dans la TDS, du fait notamment qu'on peut affecter des masses à des hypothèses composées. Ceci conduit à une interprétation satisfaisante à chaque fois qu'il s'agit de retarder l'affectation d'une confiance totale à une hypothèse singleton à l'étape de décision finale (c'est-à-dire après fusion des différents avis (ou sources)). Enfin, la décision d'un processus de classification basée sur les croyances peut être prise de manière « classique » où la décision est toujours prise en faveur d'une hypothèse simple, ou bien on peut également décider en faveur d'une hypothèse composée [Bloch et maitre 2004].

Dans les différents problèmes abordés, l'un des principaux avantages des fonctions de croyance provient du fait que la connaissance est modélisée le plus fidèlement possible. Pour la fusion d'informations, l'avantage provient essentiellement de l'étape d'agrégation qui permet généralement (suivant l'opérateur choisi) de diminuer l'incertitude sur une prédiction en utilisant la redondance et la complémentarité des sources d'informations.

Limites

Si cette théorie (la TDS) semble très séduisante, elle présente néanmoins certaines limites. Le principal défaut de cette approche est sa complexité à croissance exponentielle en fonction de la taille du cadre de discernement Ω . Énoncée pour un cadre de discernement discret, elle a surtout été employée pour des applications de reconnaissance de forme,

classification, détection. Cependant des travaux récents proposent un élargissement de la théorie au cas de cadres de discernement continus, ouvrant la voie à la résolution de problèmes d'estimation. Le cadre de discernement s'écrit alors comme un ensemble d'intervalles, ce qui augmente encore la complexité. Il a donc été reproché à la théorie des fonctions de croyance d'engendrer des temps de calcul particulièrement importants lorsque la cardinalité du cadre de discernement devient grande. Nous traiterons ce point dans le chapitre IV de ce rapport.

Bien sûr l'estimation des fonctions de masse et intrinsèquement le choix de leur modélisation doit être réalisé à partir d'une bonne connaissance des données. Une phase d'apprentissage est souvent indispensable ce qui peut limiter la généralisation, particulièrement si les données évoluent par rapport à celles de l'apprentissage (« échantillons biaisées »). Des approches adaptatives sont alors à envisager.

Dans le cadre de la fusion d'informations incertaines, l'étape de combinaison des fonctions de croyance reste sensible au choix de l'opérateur. En effet, la sensibilité de l'opérateur de Dempster (\oplus) a été démontrée dans plusieurs travaux. Dans certaines situations, cet opérateur ne peut être utilisé, c'est le cas lorsque la contrainte d'indépendance des sources d'information n'est pas vérifiée ou quand les sources ne sont pas parfaitement fiables. Lorsque la valeur du conflit K est égale à 1, les sources sont en conflit total et ne peuvent pas être fusionnées. A l'inverse, lorsque K est égal à 0, les sources sont en accord parfait. Le facteur de normalisation, qui dépend de ce conflit, rend l'opérateur de somme orthogonale sensible aux petites imprécisions des jeux de masses [Lefevre et al. 2001].

I.5 Probabilités, possibilités, croyances : Choix d'une théorie

Dans la section précédente nous avons rappelé rapidement les formalismes de fusion de sources d'information ainsi que les théories sous-jacentes. Dans cette section, nous essayons de discuter les critères de choix d'un formalisme de fusion pour la résolution d'un problème donné, ce qui nécessite un examen minutieux de la situation décisionnelle à modéliser. Un des premiers articles dans ce sens est celui de P.Smets [Smets 1998] dans lequel l'auteur essaie de résoudre la question qui résulte du manque d'un modèle unique pour représenter l'incertitude mesurée à savoir : quel modèle devrait être appliqué dans quelle situation? Et ceci en considérant que l'imprécision est souvent à la base de l'incertitude. Un travail assez récent propose un « guide pratique » pour le choix d'un langage de modélisation des imperfections de l'information dans une modélisation multicritère [Ben Amor et Martel 2004].

Dans la figure I.1 nous reportons les conclusions prises par S. Ben Amor et al. [Ben Amor et Martel 2004] pour le choix d'un formalisme (ou langage) de modélisation des imperfections de l'information et nous marquons le chemin que nous avons choisi pour opter à notre choix de la théorie de l'évidence et plus généralement à la théorie des fonctions de croyance.

Une situation où l'on envisage d'utiliser une modélisation par les probabilités implique concrètement l'identification d'une distribution de probabilités. Or, on est souvent dans l'incapacité de déterminer avec précision la distribution de probabilité appropriée. Ceci nous place dans une situation d'ambiguïté.

Les incertitudes ne sont pas toujours de nature aléatoire. Elles sont souvent dues à des imprécisions ou à des incomplétudes. La théorie des sous-ensembles flous [Zadeh 1965] se présente comme un outil privilégié pour la modélisation des situations présentant des imprécisions. Elle inclut la théorie des possibilités [Zadeh 1978] dans sa logique pour permettre la prise en compte simultanée d'imprécisions et d'incertitudes. La logique floue repose sur le concept fondamental de sous-ensemble flou qui résulte d'un assouplissement de celui de sous-ensemble d'un ensemble donné. C'est l'instrument qui nous permet de représenter la notion de classe dont les limites sont mal définies.

Bien que la théorie des sous-ensembles flous permette de traiter des données numériques ainsi que des données en langage naturel, elle ne permet pas de traiter l'imprécision et l'incertitude qui peuvent les entacher dans le même formalisme. En revanche, la théorie des possibilités permet la manipulation de l'incertitude sur des connaissances imprécises ou vagues.

La théorie de l'évidence est plus générale que celle des probabilités ou celle des possibilités. La théorie de l'évidence accepte toutes les répartitions possibles de la masse initiale de croyance entre les divers événements de 2^Ω . Deux situations particulières ont d'ailleurs été mises en évidence puisqu'elles conduisent aux théories des possibilités et des probabilités comme cas particuliers de la théorie de l'évidence. Dans la première, les événements ne sont affectés de masses de croyance non nulles que s'ils sont concordants, les éléments focaux sont alors emboîtés. Dans la deuxième, les croyances émises concernent des éléments de Ω pris individuellement, les éléments focaux sont donc des singletons de Ω .

I.6 Conclusion

La synthèse des différentes approches de fusion fait ressortir l'importance de la théorie des fonctions de croyance et des fonctions de masse dans la modélisation de la connaissance et son adéquation avec les problèmes de la fusion des sources d'informations. C'est ainsi que nous nous intéressons de plus près à cette approche dans le chapitre qui suit et nous traitons ses variantes et ses extensions.

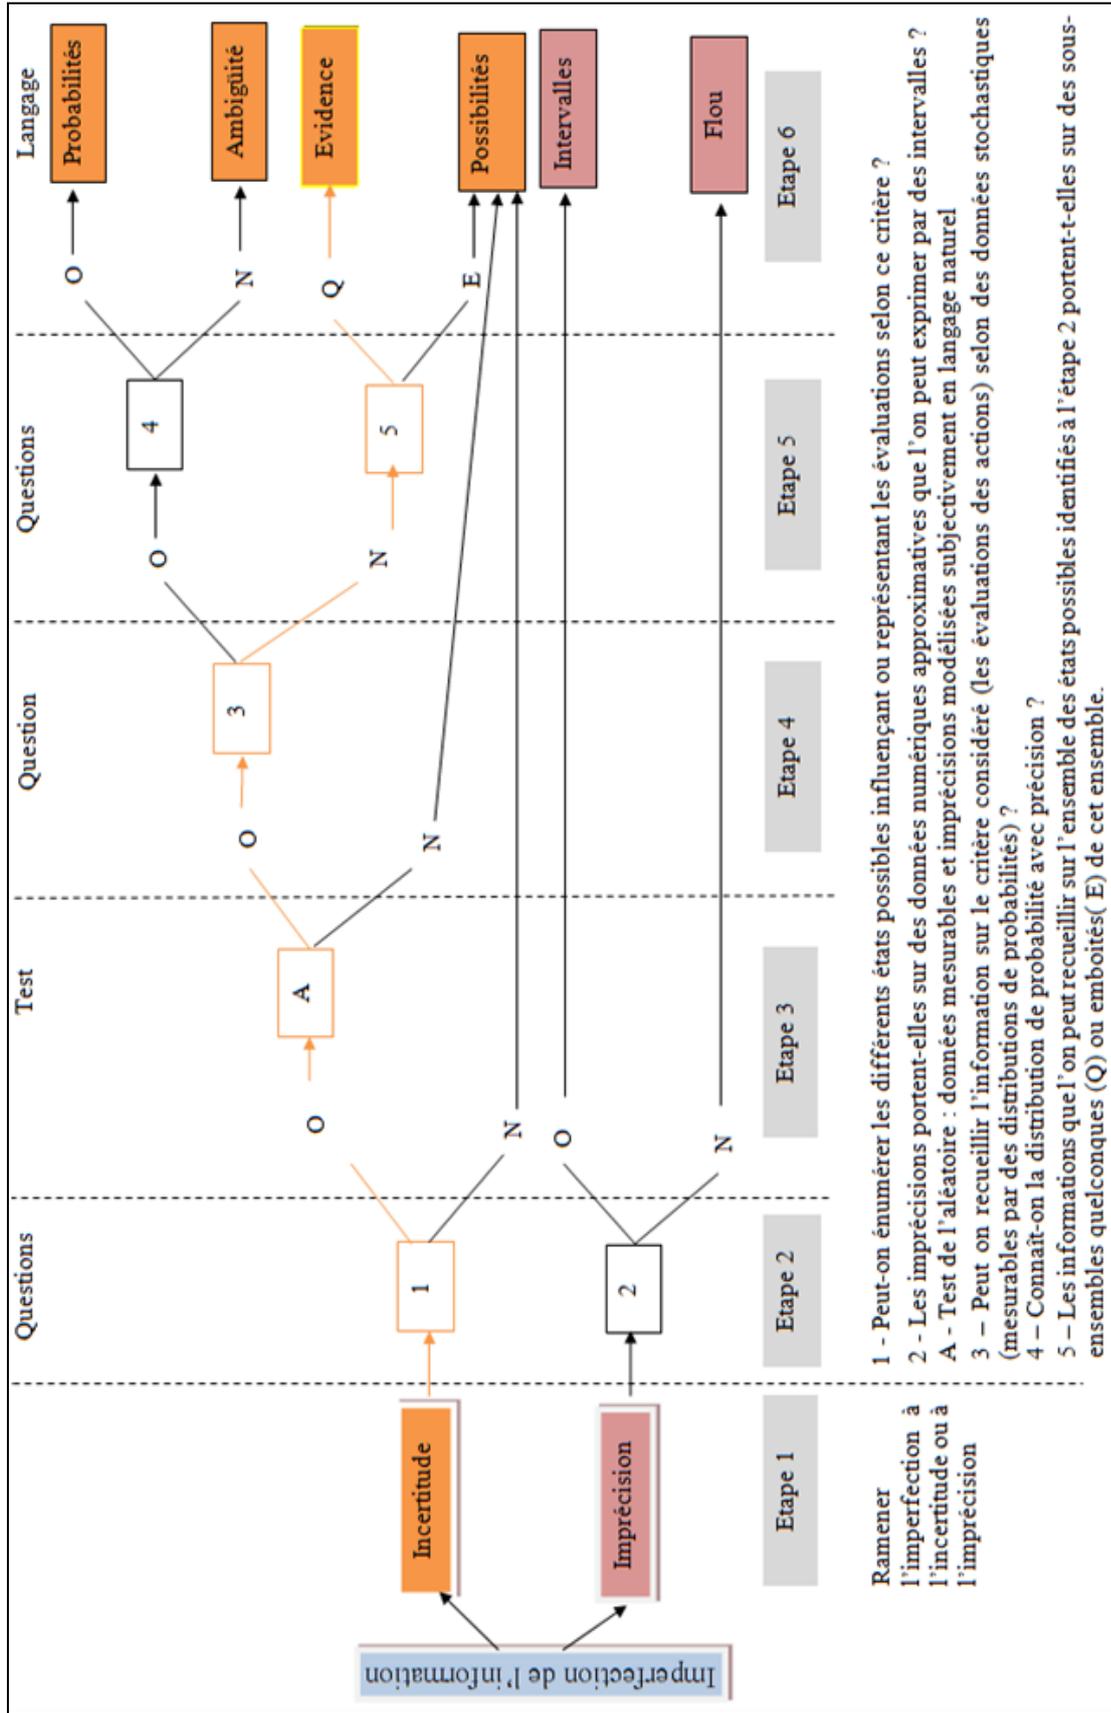


Figure I.1 .Choix d'un langage de modélisation des imperfections de l'information D'après [Ben Amor 2004]

CHAPITRE II

THÉORIE DES FONCTIONS DE CROYANCE

CHAPITRE II

Théorie des fonctions de croyance

II.1 Introduction

Nous considérons dans ce chapitre la fusion de sources d'informations du point de vue de la théorie des fonctions de croyance et ses différentes générations (ou variantes).

La théorie de Dempster-Shafer (TDS) a été à la base de la théorie des fonctions de croyance et traite le cas où les hypothèses élémentaires ($k \geq 2$) de l'ensemble de définition sont exhaustives et exclusives [Shafer 2001] [Smets 1994]. Une interprétation de la TDS dans le cas de non exhaustivité des hypothèses est le modèle des croyances transférables (MCT). Une extension de la TDS dans le cas d'hypothèses non exclusives est la théorie de Dezert-Smarandache (DSmT). Un travail unificateur des différentes théories en se basant sur leurs points communs et leurs disparités est présenté par F. Smarandache dans [Smarandache 2004].

II.2 Modèle de croyance transférable

Ce modèle proposé par Ph. Smets en 1978 fournit une interprétation cohérente du modèle de Shafer (1976). Celui-ci propose des fonctions de croyance comme cadre général de représentation des incertitudes, englobant la théorie des probabilités comme cas particulier. Ph. Smets a enrichi le modèle de Shafer par une interprétation subjectiviste, non probabiliste appelée Modèle des Croyances Transférables (MCT). L'appellation vient du fait qu'on transfère la croyance allouée initialement à une proposition vers un sous-ensemble plus spécifique de celle-ci [Smets 1990a][Smets 1990-b][Smets 2000].

II.2.1 Niveau crédal et niveau pignistique

Dans cette théorie, deux niveaux peuvent être distingués : le niveau crédal où les croyances sont modélisées et révisées, et le niveau pignistique dans lequel les fonctions de croyance sont transformées en fonctions de probabilité, dites pignistique, pour la prise de décision.

II.2.1.1 Niveau crédal

Le niveau crédal est composé de deux parties :

- une partie statique : dans cette partie statique, il s'agit de représenter les informations et le calcul de masse, des fonctions de crédibilités et de plausibilité. Dans cette théorie les fonctions de masse sont couramment appelées fonctions élémentaires de croyance ou BBA (pour Basic Belief Assignment).
- Et une partie dynamique dans laquelle il s'agit de combiner les croyances et de raisonner sur la gestion du conflit. L'application de la règle de conditionnement pour le transfert de croyance est à l'origine de la dynamique du niveau crédal.

Composante dynamique de la TBM :

La partie dynamique du MCT concerne la révision des croyances suite à la prise de connaissance de nouvelles informations. Le mécanisme de base est la règle de conditionnement de Dempster. Ayant défini une distribution de masse m , supposons que l'on vienne à apprendre que la proposition $H \in B \subseteq \Omega$ est vraie. On en déduit une nouvelle distribution $m(\cdot|B)$ en transférant la part de croyance allouée à A vers $A \cap B, \forall A \subseteq \Omega$ tels que $A \cap B \neq \emptyset$, on obtient donc la masse conditionnelle suivante décrite par l'équation (2.1) :

$$m(A|B) = \begin{cases} c^{-1} \sum_{X \subseteq \bar{B}} m(A \cup X) & \text{si } A \subseteq B \text{ et } A \neq \emptyset \\ 0 & \text{si } A \not\subseteq B \text{ ou } A = \emptyset \end{cases} \quad (2.1)$$

$$\text{avec } c = 1 - \sum_{X \subseteq \bar{B}} m(X)$$

II.2.1.2 Niveau pignistique

Une fois que les différentes sources ont été modélisées et combinées, il est nécessaire de prendre des décisions fondées sur la maximisation d'un critère. Le MCT propose de replacer le processus de décision dans un cadre probabiliste en introduisant la notion de probabilité pignistique $BetP$, obtenue à partir de la croyance par transformation pignistique. Cette transformation consiste à choisir une distribution de probabilité particulière dite « pignistique », obtenue en répartissant la masse de croyance $m(B)$ à parts égales entre les éléments de B , pour tout $B \in 2^\Omega$. Ainsi, la transformation pignistique est définie par l'équation (2.2) :

$$BetP(A) = \sum_{B \in 2^\Omega, B \neq \emptyset} \frac{|A \cap B|}{|B|} \frac{m(B)}{1 - K} \quad (2.2)$$

Le maximum de probabilité pignistique est généralement considéré uniquement sur les hypothèses singletons H_i à cause de l'additivité des probabilités. Sur des hypothèses singletons

on obtient l'équation (2.3) de calcul de la probabilité pignistique suivante :

$$BetP(H_i) = \frac{1}{1-K} \sum_{H_i \in B, B \neq \phi} \frac{m(B)}{|B|} \quad (2.3)$$

II.2.2 Règle de conditionnement

Le transfert de croyance dans le MCT satisfait la règle de conditionnement de Dempster. Notons $m(\cdot)$ la masse d'évidence sur l'espace propositionnel $\{\Omega, 2^\Omega\}$. Supposons que la nouvelle information suppose que la vérité est dans $B \in 2^\Omega$. La masse est alors transformée vers $m(\cdot|B)$. On en déduit une nouvelle structure de croyance en transférant la part de croyance initialement allouée à A vers $A \cap B$, pour tout $A \subseteq \Omega$ tels que : $A \cap B \neq \phi$.

La masse conditionnelle qui résulte est notée $m[B](\cdot)$ (les crochets traduisent le conditionnement) et ces éléments sont donnés par la règle de conditionnement de Dempster non normalisé exprimé par l'équation (2.4) suivante:

$$m[B](A) = \begin{cases} \frac{1}{1 - \sum_{C \subseteq \bar{B}} m(C)} \sum_{C \subseteq B} m(A \cup C) & \text{si } A \subseteq B \text{ et } A \neq \phi \\ 0 & \text{si } A \not\subseteq B \text{ ou } A = \phi \end{cases} \quad \text{et } m(\phi|B) = 0 \quad (2.4)$$

Ainsi, $m[B](A) = 0$ si B n'est pas inclus dans A et $mB = 1$. Ce conditionnement s'écrit également sous une forme plus pratique, à partir de la fonction de plausibilité, pour tout $B \in 2^\Omega$ par l'équation (2.5) :

$$Pl(A|B) = \frac{Pl(A \cap B)}{Pl(B)} \quad (2.5)$$

Le conditionnement peut s'écrire sous une autre forme en l'interprétant simplement comme la combinaison de et d'une fonction de masse m_B exprimant la certitude en B (c'est-à-dire $m_B(B) = 1$), ainsi pour tout $A \in 2^\Omega$ nous avons l'équation (2.6):

$$m[B](A) = m(\cdot) \wedge m_B(A) = \sum_{A=B \cap C} m(C) \quad (2.6)$$

avec \wedge : un opérateur conjonctif.

Pour différencier entre la somme conjonctive normalisée et non normalisée, notons par \odot l'opérateur de somme orthogonale de Dempster non normalisée. Dans le cas particulier de la somme conjonctive (non normalisée), la règle de conditionnement s'écrit telle que décrite par l'équation (2.7) suivante :

$$m[B](.) = m \odot m(.|B) \text{ avec } m(B|B) = 1, B \subseteq \Omega \quad (2.7)$$

II.2.3 Matrice de spécialisation

Le conditionnement peut être écrit sous une forme matricielle $m^{S_{1,2}} = C . m^{S_1}$ ce qui revient à une mise à jour de m^{S_1} par m^{S_2} (ou encore m_B). Dans le cas d'une combinaison conjonctive ($m^{S_{1,2}} = m^{S_1} \wedge m^{S_2}$), la matrice C n'est autre que la matrice de spécialisation. Dans le cas d'une combinaison disjonctive, la matrice C est une matrice de généralisation.

La matrice de spécialisation SP permet d'indiquer comment va s'effectuer le transfert d'évidence. Chaque élément de cette matrice s'écrit comme suit (équation 2.8) :

$$SP(A, B) = m[B](A), \quad \forall A, B \subseteq \Omega \quad (2.8)$$

Soit $SP(A, B)$, la proportion de A transférée au sous ensemble B de A alors la matrice vérifie l'équation (2.9) :

$$\sum_{B \subseteq A} SP(A, B) = 1, \text{ et } \forall B \not\subseteq A, SP(A, B) = 0 \quad (2.9)$$

Les proportions pour tous les couples A et B peuvent être mises sous forme de la matrice . Cette matrice donne une information précise sur la manière dont va s'opérer le transfert d'évidence pour le jeu de masse initial, compte tenu des informations supplémentaires. Le nouveau jeu de masse se déduit alors par l'équation (2.10):

$$\forall B \subseteq \Omega, m^{S_{1,2}}(B) = \sum_{A \subseteq \Omega} SP(A, B) \times m^{S_1}(A) \quad (2.10)$$

La matrice de spécialisation ne peut être établie que dans l'hypothèse du monde ouvert. Cette matrice peut être utilisée pour représenter les règles de combinaison et de conditionnement de Dempster. La notion de spécialisation est alors plus générale que la théorie de l'évidence [Denoeux 2005 b].

II.2.4 Interprétation et gestion du conflit par la MCT

L'interprétation du conflit dépend de l'hypothèse du monde ouvert ou fermé. Dans l'hypothèse du monde ouvert, $m(\phi)$ est la masse de croyance allouée à l'hypothèse $H_i \notin \Omega$. Par contre dans l'hypothèse du monde fermé, on impose $m(\phi) = 0$. Dans le MCT, Ph.Smets travaille dans un monde ouvert, ce qui signifie qu'il autorise l'hypothèse recherchée à ne pas appartenir au cadre de discernement.

Smets considère que les sources à fusionner sont fiables et préconise alors de ne pas redistribuer la masse conflictuelle sur l'ensemble des propositions mais uniquement sur l'ensemble vide. La combinaison qu'il a proposée est décrite par l'équation (2.11) suivante:

$$\begin{cases} m(A) = \sum_{B \cap C = A} m^{S_1}(B) \times m^{S_2}(C), \quad \forall A \subset 2^\Omega \\ m(\phi) = K \end{cases} \quad (2.11)$$

Le conflit (ou inconsistance) K est affecté à l'ensemble vide. D'où l'équation suivante (2.12) :

$$(m^{S_1} \oplus m^{S_2})(\phi) = \sum_{A \cap B = \phi} m^{S_1}(A) \times m^{S_2}(B) \quad (2.12)$$

Lorsque une au moins des sources est fiable, l'opérateur de somme disjonctive peut être utilisé et s'exprime comme le décrit l'équation (2.13) suivante :

$$(m^{S_1} \oplus m^{S_2})(C) = \sum_{A \cup B = C} m^{S_1}(A) \times m^{S_2}(B) \quad (2.13)$$

⊕ Étant l'opérateur disjonctif non normalisé proposés par Ph. Smets.

La moyenne des masses issues de différentes sources (qu'on note M) est utilisée par d'autres auteurs et s'exprime dans le cas de n sources comme l'illustre l'équation (2.14) :

$$M = \frac{1}{n} \sum_{i=1}^n m^{S_i} \quad (2.14)$$

II.2.5 Intérêt

L'intérêt de la MCT peut se résumer par les points suivants :

- La séparation entre le niveau crédal, où les croyances sont définies et estimées, et le niveau pignistique, où les croyances sont employées pour la prise de décision.
- Le théorème de Bayes généralisé : Smets a proposé une généralisation du théorème de Bayes dans le cadre du MCT qu'il a nommé « théorème de Bayes généralisé » (TBG). Par rapport à sa version probabiliste, le TBG est capable de manipuler des fonctions de croyance. Outre le fait que les fonctions de croyance permettent une modélisation plus fine de la connaissance et qu'elles généralisent les probabilités et les possibilités, elles permettent de modéliser la méconnaissance sur l'a priori nécessaire au calcul de la distribution à posteriori.
- Le modèle de croyance transférable traite la fonction de masse conditionnelle. Les fonctions de masse conditionnelles correspondent aux fonctions conditionnelles de probabilité, qui sont employées dans des réseaux Bayésien. La différence vient du fait que les fonctions de masse conditionnelles décrivent les croyances sur des ensembles tandis que la fonction conditionnelle de probabilité définit la croyance sur tous les éléments (hypothèses singletons).

- Le monde ouvert (permis dans le MCT) permet par exemple de redéfinir le cadre de discernement en ajoutant une hypothèse en fonction de la valeur de la masse sur l'ensemble vide. Cette nouvelle hypothèse peut correspondre à une hypothèse de rejet.
- Historiquement, la forme normalisée est celle proposée par Dempster et Shafer, tandis que la forme non normalisée a été proposée plus tard par Smets [Smets 1990], notamment pour aborder les mondes ouverts. Ainsi, pour la forme normalisée, la fonction de masse obtenue par combinaison a tendance à renforcer la croyance sur les décisions pour lesquelles les sources sont concordantes, et à l'atténuer en cas de conflit. La forme non normalisée est aujourd'hui la plus utilisée car il a été démontré que le fait de normaliser masque le conflit.

II.2.6 Limites

- Une masse positive sur l'ensemble vide peut être interprétée de différentes manières et peut poser quelques problèmes. Le passage du monde ouvert au monde fermé consiste à redistribuer la masse de l'ensemble vide sur les autres sous-ensembles de 2^Ω . Plusieurs règles de redistribution existent.
- Pour pouvoir choisir entre combinaison conjonctive et disjonctive, on doit disposer d'information concernant la fiabilité des sources à combiner.

Le modèle des croyances transférables a été développé pour fournir un modèle de représentation de la croyance quantifiée (mesurée), et prend en charge les spécificités des connaissances des experts [Mercier et al. 2007]. Une comparaison entre TDS et MCT et une mise en valeur des apports du modèle des croyances transférable dans l'interprétation et l'extension des bases de la théorie des croyances introduite par Dempster et Shafer (TDS) est illustrée dans le tableau II.1 suivant. On en déduit une plus grande souplesse du MCT par rapport aux bases introduites par la TDS. Nous mettons l'accent sur les différences entre la TDS et le MCT au niveau des points suivants : contraintes sur les hypothèses du cadre de discernement, types de relations entre sources d'informations à fusionner, fonctions de prise de décision, règles de combinaison et techniques d'estimation des fonctions de masse.

	TDS	MCT
Description	Théorie de Dempster-Shafer Formalisme mathématique par G.Shafer [Shafer 1976]	Modèle d'interprétation des fonctions de croyance [Smets 1990 a] [Smets 1990 b] <ul style="list-style-type: none"> ➤ Cadre axiomatisé et formalisé ➤ Interprétation basée sur la notion d'agent (notion liée à l'IA et équivalent à une source dans notre problème de fusion)
Cadre de discernement	<ul style="list-style-type: none"> ▪ Hypothèses exclusives ▪ Exhaustif ▪ Fonctions de croyances des différentes sources définies sur le même cadre de discernement 	<ul style="list-style-type: none"> ▪ Hypothèses exclusives ▪ peut ne pas être exhaustif ▪ <i>outils</i> : performants et adaptés lorsque les cadres de discernement sont différents : <ul style="list-style-type: none"> ○ <i>raffinement & grossissement</i> ○ <i>marginalisation</i> ○ des outils pour calculer les masses sur l'espace commun
Sources d'information	<ul style="list-style-type: none"> ▪ distinctes 	<ul style="list-style-type: none"> ▪ pas nécessairement distinctes
Prise de décision	<ul style="list-style-type: none"> ▪ fonction de crédibilité ▪ fonction de plausibilité 	<ul style="list-style-type: none"> ▪ fonction de crédibilité ▪ fonction de plausibilité ▪ fonction d'implicabilité ▪ fonction de communalité ▪ fonction de probabilité pignistique (répartir de manière équiprobable la masse d'une proposition sur les hypothèses contenues dans cette proposition)
Règles de combinaison	<ul style="list-style-type: none"> ▪ règle <i>conjonctive</i> : pour des sources distinctes et fiables, augmente le conflit si sources discordantes 	<p>Dans le cas de sources discordantes :</p> <ul style="list-style-type: none"> ▪ règle <i>conjonctive</i> <p>Dans le cas de sources discordantes :</p> <ul style="list-style-type: none"> ▪ règle <i>disjonctive</i> ▪ règle <i>adaptative</i> <p>Dans le cas de sources non distinctes :</p> <ul style="list-style-type: none"> ▪ <i>outil</i> : nouvelles règles de combinaisons ○ règle <i>conjonctive prudente</i> (CCRC) ○ règle <i>disjonctive hardie</i> (BDRC)

Détermination de la distribution de masses	<ul style="list-style-type: none"> ▪ distribution de masses d'évidence : pas de règles pour l'estimation de ces fonctions de masses 	<ul style="list-style-type: none"> ▪ nomination Basic Belief Assignment (BBA) ▪ Introduit le Principe du Minimum d'information (PMI) : Lorsque l'on doit choisir une BBA parmi un ensemble de BBA possibles, le PMI impose de choisir la moins engagée (moins informative), <ul style="list-style-type: none"> ○ quantitativement : choisir la BBA maximisant l'incertitude (mesure de la non-spécificité) ▪ <i>Théorème de Bayes Généralisé</i> : c'est un mécanisme d'inférence évidentielle ▪ <i>Inférence ascendante</i> (problème de diagnostic : déterminer les causes d'une observation) <i>Ou</i> ▪ <i>Inférence descendante</i> (problème de prédiction : déterminer les effets d'une hypothèse).
--	--	---

Tableau II.1. Comparaisons entre TDS et MCT

II.3 Théorie de Dezert-Smarandache

II.3.1 Principe général

La théorie de Dezert-Smarandache (DsmT) se base sur un cadre de discernement généralisé, comme l'ensemble de tous les éléments construits à partir des éléments de Ω avec les opérateurs ensemblistes de conjonction (notés \cap) et de disjonction (notés \cup). Ce qui implique des jeux de masse généralisés et des fonctions de croyance et de plausibilités généralisées. Cette théorie est une extension de la TDS qui ouvre de nouvelles possibilités et qui résout certains problèmes liés surtout aux relations conflictuelles entre sources. Dans ce qui suit, nous détaillons la théorie et nous dégagons ses intérêts et le plus qu'elle ajoute par rapport à la TDS dans certaines applications.

P. Djiknavorian et al. [Djiknavorian 2009] présentent un exemple de suivi de cibles aériennes par écoute électronique à l'aide des émissions radar (ESM : Ecoute Support Measures). Pour les raisons de cette application, les classes définies au départ sont les trois classes : $\Omega = \{Ami, neutre, ennemi\}$. Or deux autres classes sont prescrites pour des raisons de

stratégie de la défense canadienne : *Présumé Ami* et *Suspect*. Ces deux classes peuvent être écrites comme intersection des classes de Ω :

Présumé Ami : $\text{Ami} \cap \text{neutre}$

et

Suspect : $\text{Ennemi} \cap \text{neutre}$

Ces deux nouvelles classes s'expriment bien comme intersection des classes du cadre de discernement. La théorie de Dezert-Smarandache est particulièrement appropriée pour ce problème, parce qu'elle permet une intersection non nulle entre les trois classes originelles. Les résultats sont comparés à la TDS, laquelle ne peut raisonner que sur les trois classes originelles et montrent l'efficacité de la DSMT pour ce cas d'application.

II.3.2 Cadre de discernement généralisé

II.3.2.1 Définition

Le cadre de discernement classique (appelé aussi ensemble puissance), $\text{Parties}(\Omega) = 2^\Omega$ a été en tant que l'ensemble de tous les sous-ensembles de Ω quand tous les éléments H_i sont disjoints. La DSMT étend cette notion et définit l'ensemble hyper-puissance D^Ω comme l'ensemble de toutes les possibilités composées construite à partir de Ω avec les opérateurs ensemblistes de conjonction (notés \cap) et de disjonction (notés \cup) tel que $\forall A \in D^\Omega, \forall B \in D^\Omega, (A \cup B) \in D^\Omega$ et $(A \cap B) \in D^\Omega$.

Ainsi, la théorie de Dezert-Smarandache (DSMT) est une extension de la théorie de l'évidence qui relaxe la contrainte d'exclusivité imposée par Dempster sur les éléments qui composent le cadre de discernement.

Par exemple, pour $\Omega = \{H_1, H_2\}$, l'ensemble hyper-puissance est $D^\Omega = \{\emptyset, H_1, H_2, H_1 \cap H_2, H_1 \cup H_2\}$.

Dans la DSMT, plusieurs modèles peuvent être considérés : Modèle libre, modèle hybride ou aussi modèle de Dempster.

II.3.2.2 Modèles libre, hybride ou de Dempster

Le modèle libre

Le modèle libre représente la situation où l'ensemble hyper-puissance est considéré au complet : D^Ω .

Le modèle hybride

Le modèle hybride est obtenu à partir du modèle libre dans lequel une ou plusieurs contraintes d'intégrité sont appliquées sur l'ensemble hyper-puissance. Ces contraintes, peuvent être de plusieurs types :

(i). des contraintes d'exclusivité telles que :

$$H_i \cap H_j = \phi \text{ pour quelques } H_i, H_j \in \Omega$$

(ii). des contraintes non existentielles telles que :

$$H_i \cup H_j \cup \dots \cup H_k = \phi \text{ pour quelques } H_i, H_j, \dots, H_k \in \Omega$$

(iii). une combinaison des contraintes (i) et (ii).

Le modèle de Shafer

Le modèle de Shafer, qui représente en fait la théorie de l'évidence, est obtenu lorsque toutes les contraintes d'exclusivité sont imposées. Ainsi, l'ensemble D^Ω est réduit à 2^Ω , puisque $H_i \cap H_j = \phi, \forall H_i, H_j \in \Omega$ et $H_i \neq H_j$.

II.3.3 Jeu de masses généralisé

Chaque source d'évidence S_i est affectée par un jeu de masse généralisé de croyance décrit par l'équation (2.15).

$$m : D^\Omega \rightarrow [0,1] \quad \text{et vérifie} \quad \begin{cases} m(\phi) = 0 \\ \sum_{A \subseteq D^\Omega} m(A) = 1 \end{cases} \quad (2.15)$$

La quantité $m(A)$ est appelée masse élémentaire de croyance généralisée en A . La règle de fusion de la DsmT (dans le modèle libre) est la suivante (2.16):

$$\forall A \in D^\Omega, m(A) = \sum_{B, C \in D^\Omega, B \cap C = A} m^{S_1}(B) \times m^{S_2}(C) \quad (2.16)$$

On remarque bien que la normalisation réalisée sous la TDS pour mesurer le conflit entre les sources est inexistante dans le DsmT, elle est, pour le cas du modèle libre, directement gérée par la conjonction des hypothèses. Dans un cadre plus général, la DSmT propose une règle de fusion hybride qui permet d'intégrer les contraintes d'intégrité du problème quand elles existent. Cet aspect permet alors de traiter l'aspect dynamique de la fusion [Burrus 2003].

Une contrainte d'intégrité d'un ensemble U est en fait une impossibilité de considérer une attribution de masse à cet ensemble. La masse de l'ensemble U est alors assignée à l'ensemble vide ϕ . L'ensemble U est alors considéré comme étant un conflit et les règles de combinaisons doivent agir en conséquence.

II.3.4 Fonctions de croyance et de plausibilité généralisées

A partir de tout jeu de masse généralisé $m(\cdot)$ et pour tout élément de D^Ω , les fonctions de crédibilités (Cr) et de plausibilité (Pl) peuvent être définies de la façon suivante (2.17):

$$Cr(A) = \sum_{B \in D^\Omega, B \subseteq A} m(B) \quad \text{et} \quad Pl(A) = \sum_{B \in D^\Omega, A \cap B \neq \Phi} m(B) \quad (2.17)$$

Notons que contrairement à la TDS, la notion de complémentarité (équation 1.17) n'a pas de sens dans la DSMT puisque le principe de tiers exclus (Le principe du tiers exclu soutient que, de deux propositions contraires, si l'une est vraie, l'autre est nécessairement fausse, et réciproquement, et il n'y a pas de troisième solution possible) est réfuté en autorisant la possibilité d'avoir à traiter des informations de type paradoxales telles que $\forall A \in D^\Omega, \forall B \in D^\Omega, m(A \cap B) > 0$.

Ces définitions restent cependant cohérentes avec celles que l'on peut trouver dans le cadre de la TDS lorsque les sources traitées restent incertaines [Corgne 2004].

II.3.5 Transformation pignistique généralisée

Une transformation pignistique généralisée permet de construire une mesure de probabilité subjective à partir de l'ensemble de $m(\cdot)$, définie cette fois sur l'hyper-power set D^Ω . Cette transformation est réalisée comme le décrit l'équation (2.18) comme suit :

$$BetP(H_i) = \sum_{A \in D^\Omega} \frac{C_M(A \cap H_i)}{C_M(A)} m(A), \forall H_i \in D^\Omega \quad (2.18)$$

Avec $C_M(A)$ correspondant à la cardinalité de la proposition A pour le modèle de la DST étudié [Smarandache et Dezert 2005].

Cette transformation permet, comme pour la TBM, de prendre une décision rationnelle (par maximum de probabilité pignistique) en fonction des masses de croyance généralisées.

II.3.6 Intérêt : Gestion du conflit avec la théorie de Dezert-Smarandache

La théorie de Dempster-Shafer présente une difficulté de gestion du conflit généré par l'application de la règle de fusion de Dempster pour le cas de sources d'évidence fortement conflictuelles. La théorie de Dezert-Smarandache offre de nouvelles règles de fusion permettant d'intégrer formellement les contraintes d'intégrité du problème (quand elles existent) et de travailler avec n'importe quel type de modèle (modèle libre sans contrainte, modèle hybride ou modèle de Shafer) [Smarandache et Dezert 2005]. Une application de la DSMT est apparue dans [Smarandache et Dezert 2006] et montre l'efficacité de cette généralisation.

Plutôt que d'être représentées par l'ensemble vide, les nouvelles hypothèses sont construites à partir des éléments de Ω , et sont des éléments de l'ensemble hyper-puissance D^Ω . L'ensemble D^Ω est réduit à l'ensemble 2^Ω lorsque l'hypothèse d'exclusivité des éléments est respectée. De plus, la DSMT travaille avec des modèles plus généraux que celui de Shafer (Nouveaux modèles par rapport au modèle de Dempster : modèle libre et hybride) et propose

dans ces modèles de nouvelles règles de fusion : une dans le modèle libre et une dans le modèle hybride [Smarandache et Dezert 2005], [Smarandache et Dezert 2006].

II.4 Justification du choix de la théorie des fonctions de croyance

Notre cadre d'étude justifie le choix de la théorie des fonctions de croyances sur les points suivants :

La nature des sources utilisées

La nature des sources utilisées est :

- Incertaine :

L'information fournie par les sources est incertaine. L'inventaire forestier par exemple est une source incertaine car le terrain est classé en polygones qui ne correspondent pas toujours à une seule classe d'occupation. En effet plusieurs polygones dans l'inventaire numérisé ont un code qui correspond à un mélange d'espèces (cas du mélange Chêne Liège et chêne Zéen, cas de la classe forêt mixte etc..). Aussi, pour un pixel donné de l'image haute résolution, on dispose au niveau de l'inventaire d'un polygone de la région qui l'entoure et non une information spécifique. De plus les sources dont on dispose n'ont pas un même référentiel temporel. La plus récente est l'image QuickBird.

- Imprécise :

L'information fournie par une source ne peut pas permettre dans certains cas de décider sur l'appartenance d'un pixel à une espèce bien déterminée, mais par un sous ensemble d'espèces (c'est-à-dire à une hypothèse composée de quelques classes semblables au niveau du critère discriminant de la source)

Nous illustrons le cas de la classification basée sur l'information spectral, par l'exemple suivant : Soient 3 classes exhaustives qui peuvent être définies par les intervalles suivantes :

$$C_1 \in [10 ..40], \quad C_2 \in [30.. 70], \quad C_3 \in [35 ..50]$$

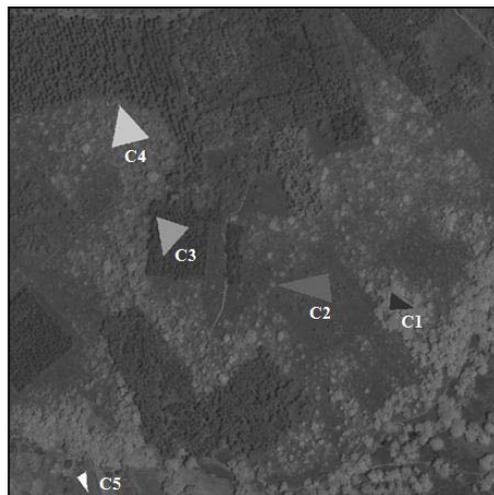
Si le point p à classer possède un niveau de gris égal à 30, donc p peut appartenir à C_1 ou à C_2 ou à C_3 . Ainsi la $m(p \in C_1 \cup C_2 \cup C_3) = 1$.

Dans ce cas, l'appartenance du point p à une des classes C_1 , C_2 et C_3 ne peut être décidée par la seule donnée de l'information spectrale. Par contre, l'affectation de ce point à une hypothèse singleton (une classe) peut être envisagée grâce à la fusion avec d'autres sources opérant avec d'autres critères (texture, structure, strates de l'inventaire, altitude).

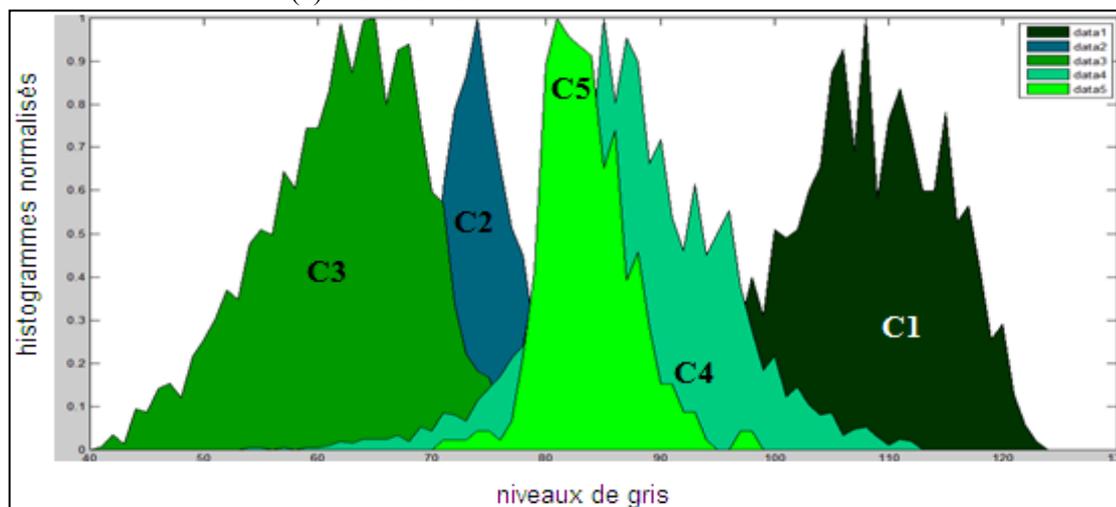
La notion d'hypothèse composée et d'affectation d'une croyance indivisible sur ces hypothèses composantes n'a été introduite qu'avec la théorie des fonctions de croyance et particulièrement la DST. C'est dans ce sens que notre choix s'est porté sur la théorie des fonctions de croyance

Chevauchement spectral et confusion entre classes

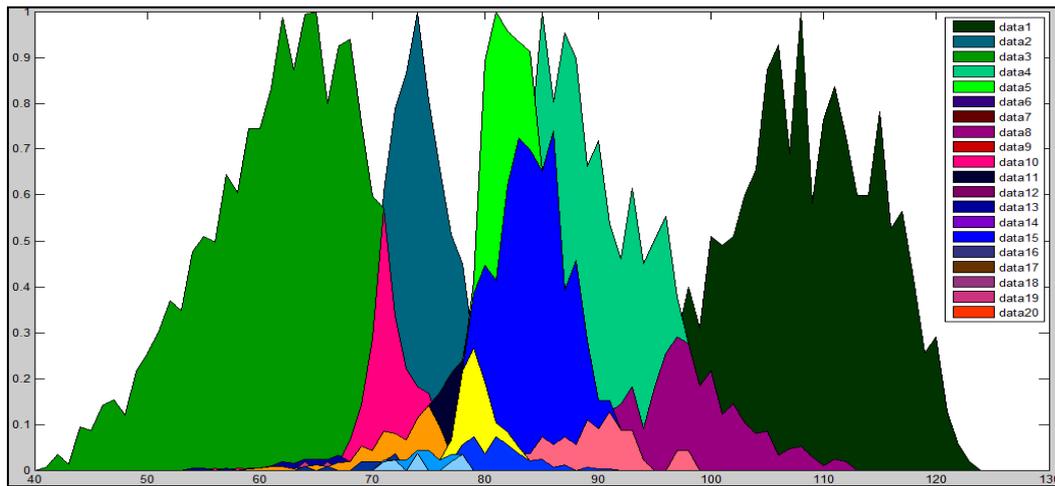
La réponse spectrale des formations forestières est de nature à présenter un chevauchement entre les différentes classes et pose un problème de gestion de l'ambiguïté spectrale qui devra être résolu dans le cadre d'une approche de fusion entre les différentes sources d'informations et des connaissances dont on dispose. Ce problème s'avère complexe si on prend en considération le nombre important de classes, les chevauchements multiples et l'évaluation des masses des unions de classes. L'analyse de l'histogramme d'une fenêtre de l'image QuickBird (figure II.1) informe sur ce chevauchement et sur la nécessité d'un formalisme pour évaluer et répartir la masse des unions qui découle des combinaisons de classes.



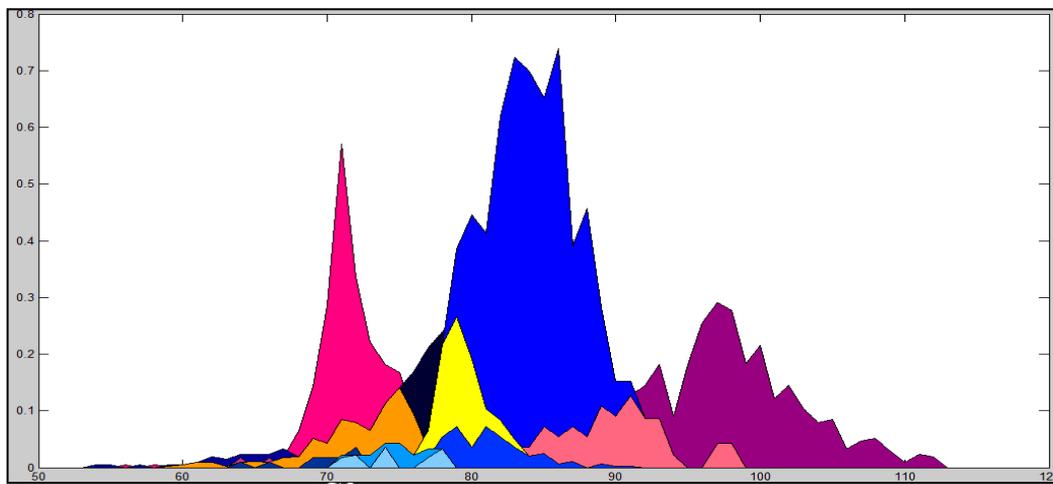
(a): Fenêtre 1 de l'IHR



(b): Histogrammes des zones d'apprentissages des 5 classes du cadre de discernement



(c): Histogrammes des zones d'apprentissages avec chevauchements



(d): Chevauchements entre histogrammes (Histogrammes des hypothèses composées)

Figure II.1. Histogrammes des zones d'apprentissages des classes du cadre de discernement avec chevauchements.

II.5 Conclusion

Dans ce chapitre nous avons présenté des extensions à la théorie des fonctions de croyance qui permettent de palier à la contrainte imposée par la TDS sur les hypothèses de l'ensemble de définition. Le cas de non exhaustivité des hypothèses est traité par le MCT, celui de la non exclusivité des hypothèses est traité par la DsmT. L'intérêt de ces approches, outre le fait qu'elles se placent dans un cadre de discernement généralisé, réside dans la gestion du conflit à travers les nouvelles règles de fusion qu'elles font intervenir. Toutefois, l'apport de ces méthodes n'intervient pas sans accentuer la complexité des fonctions de masses et des opérateurs de décision. Le chapitre IV traite le problème d'explosion combinatoire auquel est soumis le calcul des fonctions de masse et apporte des solutions pour le réduire.

CHAPITRE III

APPLICATION DE LA THEORIE DES FONCTIONS DE CROYANCE A LA CLASSIFICATION D'IMAGES

CHAPITRE III

Application de la théorie des fonctions de croyance à la classification d'images

III.1 Introduction

Un processus de classification basé sur la théorie des fonctions de croyance passe obligatoirement par l'estimation des fonctions de masses des éléments de 2^Ω (avec Ω l'ensemble des hypothèses du cadre de discernement). Nous nous intéressons dans la section 2 au raisonnement évidentiel flou. La section 3 est consacrée à la détermination des éléments focaux. La section 4 s'intéresse aux approches d'estimations de fonctions de masse. Ainsi, nous nous intéressons dans ce chapitre aux approches les plus utilisées et dont les plus récentes sont des approches hybrides adoptant le raisonnement évidentiel flou et/ou l'utilisation des informations contextuelles ou de voisinage.

III.2 Raisonnement évidentiel flou

Le raisonnement évidentiel flou est apparu suite à des travaux qui ont montré que l'incertitude prise en compte par la théorie de l'évidence (des fonctions de croyance) ne prend pas en charge la notion d'« incertitude floue ».

III.2.1 Motivations

Les théories des probabilités, possibilités et des fonctions de croyance n'ont pas la même sémantique ni le même pouvoir de représentation. Ces constatations sont une motivation pour des techniques hybrides de représentations permettant de représenter simultanément des informations dont les types d'imperfections sont différents. On peut ainsi définir des probabilités d'ensembles flous, des fonctions de croyance sur des sous-ensembles flous, etc.

Les premiers travaux [Denoeux 1995 a] introduisant l'aspect flou dans la théorie de l'évidence ont été motivés par l'insuffisance constatée dans la théorie de l'évidence concernant la non prise en compte de l'incertitude floue par cette théorie. Ces travaux ont commencé au milieu des années 90.

III.2.1.1 Incertitude floue

Dans [Boudraa et al. 2004], l'incertitude est classée en trois types :

- l'incertitude de nature probabiliste : c'est le cas de l'incertitude liée à des phénomènes aléatoires (le moment et le caractère d'un événement que l'on ne peut pas prédire) ou à un manque de connaissance (la bande de fréquence du système d'acquisition pour une image à traiter).
- l'incertitude due au manque de spécification : l'examen des écarts existants entre des résultats de mesures de différents laboratoires révèle que ces différences étaient dues à des interprétations différentes de la spécification. Les incertitudes sont donc présentes à la fois lors du processus de spécification et du processus de vérification (incertitude de méthode et de mise en œuvre).
- l'incertitude floue (fuzziness): Pour l'incertitude floue, il s'agit de situations où les frontières des ensembles (classes) considérés ne sont pas définies rigoureusement [Bloch 1996 c], [El-Shayeb 1999], [Kaftandjian et al. 2003].

En télédétection, les images se référant à des scènes naturelles [Khedam et al. 2006], [Pieczynski 2004], sont souvent accompagnées d'une quantité de flou due à l'imprécision des valeurs des niveaux de gris et à l'ambiguïté créée par les systèmes d'acquisition [Guo et al. 2006]. En effet, une mesure aberrante issue d'un capteur est due soit à un mauvais fonctionnement du capteur lors de son acquisition, soit à une mauvaise évaluation de la plage de fonctionnement du capteur lors de l'apprentissage. Les informations à modéliser issues d'un capteur ne sont jamais parfaites en raison du principe même de l'acquisition d'images (passage de l'espace 3D au plan 2D).

L'interprétation des classes d'occupation de la couverture terrestre révèle souvent des incertitudes floues et non floues. L'incertitude non floue évoque des frontières mal définies entre régions. Cette incertitude (non floue) se situe autour de l'appartenance des éléments ou événements à des ensembles nets.

Ces situations nécessitent de combiner les approches Dempster-Shafer et les sous-ensembles flous. Une approche faisant intervenir à la fois la théorie de Dempster-Shafer ainsi que les sous-ensembles flous s'avère en mesure de modéliser ce genre d'incertitudes mixtes. Une manière d'estimer les fonctions de masse se référant à des éléments focaux flous est d'utiliser des fonctions d'appartenance floues.

La solution aux problèmes d'incertitude floue est donc d'introduire la fuzzification dans les fonctions de masses et donc aux éléments focaux. La notion d'élément focal flou a été introduite au milieu des années 90 en reconnaissance de formes floues [Zouhal et Denoeux 1996], dans l'apprentissage et dans le cadre du MCT [Denoeux 1999].

III.2.1.2 Ambiguïté

L'ambiguïté est un cas particulier d'incomplétude. La définition d'ambiguïté et de mesure d'ambiguïté n'est pas universelle. En effet, le terme « ambiguïté » prend selon ses auteurs et le domaine d'étude des significations assez différentes. Certains travaux ont mis l'accent sur la notion de mesures d'ambiguïté dans la théorie de l'évidence, à l'origine c'était les travaux de G.Klir [Klir et Yuan1995] qui ont permis de définir une mesure d'incertitude globale constituée des deux types d'incertitude coexistant dans cette théorie qui sont le désaccord (ou doute) et la non spécificité. Ces mesures obéissent à certaines conditions. Des travaux plus récents proposent des mesures d'ambiguïtés (MA) liés à une fonction de croyance [Henry 2002], [Jousselme et al. 2006], [Klir et Lewis 2008].

III.2.2 Généralisation de la théorie des croyances aux ensembles flous

Nous commençons par définir un élément focal flou ensuite nous passons à sa détermination et l'estimation des fonctions de masses associées.

III.2.2.1 Element focal flou

Rappelons qu'un élément focal (ou encore une structure de croyance floue) est un élément du référentiel de définition 2^Ω dont la masse est non nulle. Nous notons un élément focal par ef . Dans cette section nous introduisons la notion d'élément focal flou.

Les éléments focaux tels que définis dans la théorie de Dempster-Shafer et ses extensions (TBM, DSmt) sont des éléments focaux nets (non flous) puisqu'il s'agit d'ensembles non flous de Ω . Le fait que la théorie de l'évidence de Dempster-Shafer (TDS) soit incapable de représenter le flou (vague) a motivé le remplacement des éléments focaux nets dans la TDS par des éléments focaux flous. Ce qui a donné lieu à une généralisation de la TDS qui a été nommée FDS (pour Fuzzy Dempster-Shafer) pour désigner le raisonnement évidentiel flou.

Un élément focal flou peut être exprimé sous la forme discrète suivante illustrée par l'équation (3.1):

$$A = \left\{ \frac{\mu_A(x_1)}{x_1}, \dots, \frac{\mu_A(x_i)}{x_i}, \dots, \frac{\mu_A(x_{|A^0|})}{x_{|A^0|}} \right\}, \quad \forall A, x_i, m(A) \neq 0, \mu_A(x_i) \neq 0, \forall i \in \{1, \dots, m\} \quad (3.1)$$

Avec :

A est associé à certains événements comme des classes ou des termes linguistiques dans le cadre de discernement Ω , c.à.d. : $A \in 2^\Omega$

$\mu_A(x_i)$ est le degré d'appartenance de l'élément x_i à A ,

U est l'univers du discours pour les éléments focaux flous,

$x_i \in U$ et $A^0 = \{x_1, \dots, x_{|A^0|}\}$ est l'ensemble support de l'ensemble flou A . Sachant qu'on appelle $\text{supp}(A) = \{x \in U \mid \mu_A(x) \geq 0\}$, d'où $A^0 \subseteq U$.

$|A^0|$ représente la cardinalité de A^0 .

La définition ci-dessus est apparue de manière à peu près similaire dans [Zhu et Basir 2005 a] et [Zouhal et Denoeux 1996].

Une variable linguistique est représentée par un triplet (V, U, T_V) où V est la variable elle-même, U son domaine et T_V l'ensemble des entités caractérisant la variable. Considérons par exemple la variable *distance* définie sur l'ensemble des entiers positifs et caractérisée par les ensembles flous proche, moyen et éloigné. La variable distance est alors représentée par le triplet suivant : $\{distance, R^+, (proche, moyen, éloigné)\}$. est appelée *univers du discours*.

III.2.2.2 Structure d'évidence floue

Associé avec une source d'information, les éléments focaux flous et les masses construisent ensemble une *structure d'évidence floue* notée par FS et décrite par l'équation (3.2) suivante :

$$FS = \{(A, m(A), \mu_A(x)) \mid A \subseteq \Omega, x \in U\} \quad (3.2)$$

Comme dans la TDS trois étapes de traitement sont essentiellement requises quant la FDS est utilisée. Ces étapes sont :

- 1) Formuler une structure d'évidence floue pour chaque source d'information
- 2) Combiner les structures d'évidence floues des différentes sources
- 3) Décider en se basant sur la structure d'évidence combinée.

La combinaison des structures d'évidence floues peut être réalisée en utilisant la règle de Dempster et en remplaçant l'intersection des ensembles nets par l'intersection d'ensembles flous et en repoussant la normalisation à l'étape finale. Ce qui revient à une généralisation de la règle de Dempster aux structures de croyance floues [Zhu et Basir 2003], [Zhu et Basir 2005 a], [Zhu et Basir 2005 b].

III.2.2.3 Fonction de croyance consonante

Une première voie permettant de relier les notions d'ensembles flous et de fonction de croyance passe par la théorie des possibilités. En effet, une mesure de possibilité est formellement équivalente à une mesure de plausibilité dont les éléments focaux sont emboîtés (éléments emboîtés signifie qu'ils peuvent être arrangés dans l'ordre de sorte que chaque élément focal soit contenu dans le suivant. Ainsi, pour toute paire d'éléments focaux (ef_i, ef_j) , $ef_i \subseteq ef_j$ ou $ef_j \subseteq ef_i$, ou, en d'autres termes, que les k éléments focaux de $m()$ forment une

chaîne $ef_1 \subseteq ef_2 \subseteq \dots \subseteq ef_{k-1} \subseteq ef_k$). La distribution de possibilité associée est alors une fonction de croyance consonante. Une fonction de masse de croyance est appelée consonante si les éléments focaux associées sont emboîtés (c'est-à-dire linéairement ordonnés par inclusion).

Or, une distribution de possibilité peut être définie à partir d'un ensemble flou. Une distribution de possibilité dans la théorie des possibilités est équivalente à une fonction d'appartenance floue dans la théorie des sous-ensembles flous. D'où un lien établi entre ensemble flou et une fonction de croyance consonante. Par conséquent, un élément focal flou peut être représenté par les ensembles consonants, auquel est associée une certaine masse.

Structure d'évidence floue obtenue à partir d' α -coupe

Une manière naturelle pour faire le lien entre une structure d'évidence floue $(A, m(A), \mu_A(x))$ et une structure d'évidence nette est de représenter l'ensemble flou A avec des α -coupes. En effet, sachant qu'il a été démontré qu'une mesure de plausibilité (respectivement une mesure de nécessité) dont les éléments focaux sont les α -coupes de ef est aussi une mesure de possibilités (respectivement une mesure de crédibilité), le lien entre la théorie des croyances et des possibilités apparait.

Commençons tout d'abord par expliquer la notion d' α -coupe d'un sous-ensemble flou. L' α -coupe d'un sous-ensemble flou est défini par le sous-ensemble binaire A^α de fonction caractéristique $\chi_{A^\alpha}(x)$ tels que (3.3):

$$\chi_{A^\alpha}(x) = \begin{cases} 1 & \text{si } \mu_A(x) \geq \alpha \\ 0 & \text{sinon} \end{cases} \quad (3.3)$$

Soit eff un sous-ensemble flou normalisé de Ω fini et μ_{eff} une fonction d'appartenance associée à eff . La distribution de possibilité π induite par eff est définie par l'équation (3.4) :

$$\pi(C) = \mu_{eff}(C), \forall C \in \Omega \quad (3.4)$$

Soient $\pi_1 = 1 > \pi_2 > \dots > \pi_r$ les valeurs distinctes prises par la distribution (et $\pi_{r+1} = 0$ par convention), alors $m(F_i) = \pi_i - \pi_{i+1}, i = 1, \dots, r$ est la π_i -coupe de eff . L'estimation des fonctions de masses associées aux α -coupes des éléments focaux flous ainsi obtenus revient à distribuer la masse $m(A)$ de sur ses α -coupes.

Ainsi, une α -coupe d'un élément focal flou eff_i notée α -coupe (eff_i) (ou aussi eff_i^α) est définie comme décrit par l'équation (3.5) :

$$= eff_i^\alpha = \{x \mid \mu_{eff_i}(x) \geq \alpha\} \quad (3.5)$$

Pour le calcul des fonctions de plausibilités et de crédibilités qui en découlent, J.Yen [Yen

1990] propose dans le cas discret les équations de calcul suivantes (3.6):

$$\begin{aligned} Pl_m(A) &= \sum_{i=1}^n m(\text{eff}_i) \sum_{\alpha_j} (\alpha_j - \alpha_{j-1}) \max_{H \in \text{eff}_i^{\alpha_j}} \mu_A(H) \\ Cr_m(A) &= \sum_{i=1}^n m(\text{eff}_i) \sum_{\alpha_j} (\alpha_j - \alpha_{j-1}) \min_{H \in \text{eff}_i^{\alpha_j}} \mu_A(H) \end{aligned} \quad (3.6)$$

avec $0 \leq \alpha_1 < \dots < \alpha_j < \dots \leq 1$ et $\text{eff}_i^{\alpha_j}$ est l' α_j -coupe de l'élément focal floue eff_i .

III.2.2.4 Applications

Applications médicales

L'incertitude et l'imprécision sont des concepts importants de la connaissance médicale. Un symptôme est une indication incertaine d'une maladie car il peut ou peut ne pas se produire avec la maladie. Ainsi, une mesure d'incertitude devrait être employée pour estimer le risque de la maladie quand on observe le symptôme. Des termes linguistiques par exemple : « fièvre élevée » ou « poids excessif », sont d'usage courant en décrivant des symptômes. Une mesure d'imprécision est avantageuse pour leur représentation. L'incertitude caractérise une relation entre les symptômes et les maladies, alors que l'imprécision est liée à la représentation du symptôme.

Si une règle de diagnostic est interprétée dans la TDS, son incertitude peut être décrite par les distributions de masse d'évidence. Les règles avec les valeurs assignées des masses d'évidence forment une connaissance. D'autre part, la valeur de la croyance est associée avec la crédibilité du diagnostic pour un patient examiné.

Une prémisse formulée de manière linguistique peut être considérée comme un élément focal dans la TDS. Cette prémisse peut être décrite par un ensemble flou. Si c'est le cas, les éléments focaux sont définis par des ensembles flous et l'inférence du diagnostic est exécutée selon les principes de la TDS.

Les symptômes imprécis impliquent un diagnostic « crisp ».

Exemple :

$a \equiv$ « le résultat du test X est faible » (Exemple : X est le test TSH pour les maladies de la glande thyroïde). Les valeurs qui sont les résultats du test vont être notés par x et appelées le domaine (ou l'univers de discours) de X . Généralement $x \in R$.

Par exemple l'ensemble des éléments focaux peut être par exemple :

a_1 « le résultat du test X est faible »

$a_2 \equiv$ « le résultat du test Y est haut »

$a_3 \equiv$ « le résultat du test Z est faible »

$a_4 \equiv$ « le résultat du test Y est haut et le resultat du test Z est normal »

$f \equiv$ « aucun des symptomes n'est présent »

L'ensemble des éléments focaux est $F = \{a_1, a_2, a_3, a_4\}$.

La conclusion peut être formulée comme $c \equiv$ « le patient est malade »

Chaque élément focal a une masse $m_c(a_i)$ attribuée qui doit obéir à la propriété $m(f) = 0, \sum_{a \in A} m(a) = 1$ et tels que $m_c(a_i)$ correspond à la croyance que le patient soit malade quand a_i est observée.

Discrimination

Plusieurs applications liées à la discrimination ont utilisé l'approche évidentielle floue. A cet occasion, on commence par définir brièvement le principe de la discrimination :

Le principe de la discrimination est le suivant :

On possède une suite d'observations (x_i, y_i) , chaque observation est placée dans une classe. Et on cherche à expliquer la relation entre (x, y) et la classe d'appartenance. Le but principal de ces approches est de pouvoir classer de nouvelles observations.

Une approche de la discrimination assez utilisée en reconnaissance de forme et adoptant la théorie des fonctions de croyance, consiste à considérer les éléments d'un ensemble d'apprentissage comme des sources d'information relatives au classement d'un nouveau vecteur forme. Les différentes sources sont représentées par des structures de croyance et combinées par la règle de Dempster.

Dans un problème de discrimination et plus particulièrement dans le cas d'une approche de classification supervisée basée sur l'algorithme des K-plus proches voisins, le problème peut être décrit comme suit : Chaque voisin x^i d'un vecteur forme à classer x est supposé caractérisée par un vecteur $\mu^i = (\mu_1^i, \dots, \mu_n^i)$, avec μ_j^i le degré d'appartenance de x^i à la classe C_j . Ainsi, à chaque vecteur d'apprentissage x^i est associée un sous-ensemble flou F^i de Ω en posant l'équation suivante (3.7) :

$$F^i = \left\{ \frac{\mu^i(C_1)}{C_1}, \dots, \frac{\mu^i(C_j)}{C_j}, \dots, \frac{\mu^i(C_n)}{C_n} \right\} \quad (3.7)$$

C_i étant une classe floue. L'ensemble flou F^i induit une structure de croyance consonante m^i .

L'estimation de la distribution de masse de croyance proposée dans le cas de l'algorithme de classification basée sur k plus proches voisins et la théorie des fonctions de croyance est proposée dans les travaux de Denoeux [Denoeux 1995 a] et utilisée aussi par certains travaux comme ceux de O.Basir et Z.hu [Zhu et Basir 2003], [Zhu et Basir 2005 a] peut se présenter comme l'illustre l'équation (3.8). Il s'agit en fait de définir à partir de (structure de croyance ou encore la distribution de masse associée à x^i) et de la distance d^{x,x^i} entre x et x^i , une nouvelle structure de croyance m_x^i caractérisant l'information apportée par le couple (x^i, F^i) relativement à la classe de C_i tels que α^i est un terme décroissant en fonction de la distance d^{x,x^i} :

$$\begin{cases} m_x^i(A) = \alpha_x^i m^i(A), & \forall A \in 2^\Omega - \Omega \\ m_x^i(\Omega) = 1 - \sum_{A \neq \Omega} \alpha_x^i m^i(A) \end{cases} \quad (3.8)$$

Les éléments focaux de d^{x,x^i} sont les π_i – coupes du sous-ensemble flou F^i .

Fuzzification de certains algorithmes

Les extensions à la théorie de Dempster-Shafer l'agrégant avec les notions du flou [Zhu et Basir 2003], [Zhu et Basir 2005 a] et du voisinage. Une généralisation de la théorie de Dempster-Shafer aux ensembles flous (« fuzzy Dempster–Shafer evidential reasoning ») couplée avec l'utilisation de l'algorithme des plus proches voisins a été proposée dans [German 2004 b]. D'autres travaux font appel à la logique propositionnelle comme approche de résolution de problèmes de décision sous incertitude [Provan 1989].

Des travaux tels que [Ben Tabet 2002], [Masson et Denoeux 2007], [Masson et Denoeux 2008], [Omrani et al. 2006], [Straszecka 2006], [Straszecka 2008], [Zhu et al. 2002], [Zhu et Basir 2003], [Zhu et Basir 2005 a], [Zhu et Basir 2005 b] ont travaillé sur cet aspect hybride (flou et croyance) et ont flouifié des algorithmes de classification tels que les C-Means et les K-NN (K-Nearest Neighbors) dans le but d'obtenir des fonctions de masses (appelées aussi des structures de croyance et / ou structure de croyance floue) appropriées aux types d'incertitude de l'information à classer où à la source dont elle est issue.

III.3 Détermination des éléments focaux

Dans de nombreuses applications, il est possible de disposer d'informations à priori qui permettent de déterminer de manière supervisée quels sont les éléments focaux à prendre en compte. Dans [Bell et al. 2005], les auteurs préconisent l'utilisation de méthodes d'apprentissage des éléments focaux (simples ou composés) en se basant sur les travaux

d'I.Bloch [Bloch 2005].

Toutefois, les applications en traitement d'image se basant sur la théorie de l'évidence ont été orientées initialement vers des applications en imagerie médicales et la détermination des éléments focaux découlait d'une interprétation visuelle de l'image [Bloch 1996 b] ou sur des méthodes qui ne prennent en compte que des éléments focaux singletons ou des disjonctions à deux classes [Ben Tabet 2002], [Tilie et al. 2007], [Tupin et al. 1999]. Des travaux plus récents manipulent des éléments focaux composés de plus de deux classes [Bloch 2008].

Dans un contexte multi-sources, une approche d'apprentissage des éléments focaux a été introduite dans [Le Hégar-Masclé et al. 1997] et est basée sur les intersections entre classes détectées individuellement par chaque source.

Un cas d'application a été orienté vers des images médicales relatives à un problème de maladie du cerveau [Bloch 1996 b]. Le nombre de classes pour cet exemple est de trois, et les éléments focaux des deux sources images que les auteurs traitent, sont issus d'une interprétation qui retient les classes discriminantes et les unions des classes sujettes à confusion. Ainsi, les classes non discriminées dans une source sont considérées en tant qu'élément focal composé (union des classes que l'interprète n'arrive pas à discriminer sur l'image). Des masses nulles sont assignées aux autres hypothèses composées.

Dans [Le Hégar-Masclé 1997], une autre méthode de classification non supervisée basée sur la comparaison des résultats de classifieurs mono-source est proposée. La détermination des éléments focaux dans [Le Hégar-Masclé et al. 1997] suit le raisonnement suivant :

Pour chaque source :

- S'il n'existe pas d'ambiguïté entre deux classes : $m(C_i) \neq 0$ et $m(C_j) \neq 0$ et $m(C_i \cup C_j) = 0$
- Dans le cas d'ambiguïté entre deux classes : selon les valeurs expérimentales les auteurs ont privilégié la stratégie d'affecter la même masse pour les deux classes non distinguables et leur union ($m(C_i) = m(C_j) = m(C_i \cup C_j) \neq 0$) par rapport à l'autre stratégie ($m(C_i) = m(C_j)$ et $m(C_i \cup C_j) \neq 0$)

Soient $\{C_1^1, \dots, C_{n_1}^1\}$ et $\{C_1^2, \dots, C_{n_2}^2\}$ les ensembles respectifs de n_1 classes dans l'image issu du détecteur a (source S_1) et n_2 classes dans l'image issu du détecteur b (source S_2) avant fusion.

Pour la combinaison entre les différentes sources :

- L'ensemble des singletons considéré (après combinaison) est l'ensemble des

intersections non-nulles entre les classes des différentes sources. Les auteurs considèrent que chaque classification mono-source fournit des classes singletons et donc qu'il n'y a pas d'ambiguïté au niveau mono-source.

- La combinaison des hypothèses simples fournit :

$$\{C_i^1 \cap C_j^2 \text{ tels que } C_i^1 \cap C_j^2 \neq \emptyset, i \in [1, n_1], j \in [1, n_2]\}$$

- L'ensemble des hypothèses composées :

$$\{(C_{l_1}^1 \cup \dots \cup C_{l_m}^1) \cap (C_{k_1}^2 \cup \dots \cup C_{k_n}^2) \text{ tels que } C_{l_i}^1 \cap C_{k_j}^2 \neq \emptyset, l_i \in [1, n_1], k_j \in [1, n_2]\}$$

Au niveau de la fusion, la masse des hypothèses composées s'annule.

III.4 Approches d'estimation des fonctions de masse pour la classification d'images

Dans la théorie des fonctions de croyances, la première difficulté est l'estimation des fonctions de masse. On trouve dans la littérature, différentes propositions pour les estimer. Evidemment, selon la nature et la provenance des informations impliquées dans le système de fusion, les modèles à mettre en œuvre penchent vers des fonctions de masses appropriées [Bell et al. 2005], [Bloch 2008], [Bloch et maitre 2004], [Denoeux 2005], [Guo et al. 2006], Hammal et al. 2004], [Hammal et al. 2007], [Jouan et Allard 2004], [Lefevre 1999], [Vanoorenberghe 2003], [Vanoorenberghe et al. 2003] [Yong et al. 2003].

Nous présentons dans cette partie les principales méthodes d'estimation des fonctions de masse d'évidence. Ces méthodes sont généralement dérivées des probabilités (histogrammes de niveaux de gris [Rombaut et Zhu 2002] ou des fonctions d'appartenance (tracées sous forme de fonctions triangulaire ou trapézoïdales), et utilisent divers techniques tels que l'affaiblissement [Wu et al. 2006].

III.4.1 Familles de méthodes d'estimation des fonctions de masse

Plusieurs auteurs [Bloch et maitre 2004], [Martin 2008], [Rombaut 2001] divisent les méthodes d'estimation des fonctions de masses en différentes familles de méthodes :

- Fonction à support simple : fonction qui affecte toute la masse d'une source S_j à un sous ensemble non-vide A du référentiel de définition,
- Fonction de croyance complémentaire : fonction qui divise la masse totale entre un événement et son complémentaire
- Fonction sur les singletons : dans le cas où la source ne donne d'opinions que sur les

singletons

D'autres fonctions plus « sophistiquées » obéissent à des modèles :

- Modèles probabilistes

Dans [Le Hégarat-Masclé et al. 1997], par exemple, l'estimation de la masse utilisée se base sur des probabilités conditionnelles et une normalisation à la phase de combinaison.

- Modèles de distance :

Les travaux d'estimation des fonctions de masse en utilisant l'algorithme des plus proches voisins ont commencé avec T. Denoeux [Denoeux 1995] au milieu des années 90, suivi par plusieurs chercheurs tels que H.Zhu et O.Basir en 2005 [Zhu et Basir 2005 a] et Hakan Altincay en 2007 [Altincay 2007]. Des travaux récents utilisant les Kpp (K-plus-proches voisins) font un mixage avec le flou [Zhu et Basir 2005 a], d'autres apportent une amélioration en utilisant les « ensembling techniques » [Altincay 2007]. D'autres travaux existant utilisent des règles de combinaison qui prennent en compte l'incertitude issue d'hypothèses conflictuelles [Campos 2003].

III.4.2 Estimation des fonctions de masse sur des sous-ensembles flous

Le raisonnement évidentiel flou (cf. paragraphe III.2) nécessite l'estimation de fonctions de masse sur des éléments focaux flous afin de modéliser l'incertitude floue contenue dans l'information traitée [Germain et al. 2004], [Le Hégarat-Masclé et al. 2003], [Royère et al. 2003],[Shafer 1990], [Suzuki et al. 2001 a]. Les méthodes d'estimation de ces fonctions de masse diffèrent d'une application à une autre.

III.4.2.1 Estimation de fonctions de masses en utilisant les C-moyennes floues

Dans [Ben Tabet 2002], l'estimation de la masse d'un pixel dépend de ses degrés d'appartenances et de ses informations contextuelles. Chaque pixel est caractérisé par un degré d'appartenance générée par l'algorithme des C-moyennes floues (FCM). Les fonctions d'apprentissage sont dérivées des niveaux de gris et corrigées en prenant en compte l'information spatiale du voisinage des pixels traités. D'autres travaux se basant sur les C-moyennes floues et l'information de voisinage sont apparus dans [Suzuki et al. 2001 a] et [Tessem 1993] où une nouvelle formulation adaptative évidentielle et floue des plus proches voisins a été introduite.

Dans [Masson et Denoeux 2007], les auteurs ont proposé un algorithme évidentiel des C-moyennes (ECM : Evidential C-Means) qui opère sur des *partitions crédales*. Les partitions crédales sont plus générales que les partitions nettes, floues et possibilistes. Le nombre de degrés de liberté est plus important que dans les autres types de partitions et permet donc d'envisager une meilleure modélisation et une description plus riche de données complexes. Une version noyau de l'algorithme ECM a été proposée dans [Masson et Denoeux 2008].

Déterminer une partition crédale à partir de données individus-variables revient à chercher, pour chaque individu i , les quantités $m_{ij} = m_i(A_j)$ de telle sorte que la masse m_{ij} soit d'autant plus grande que la distance d_{ij} entre i et l'élément focal A_j est faible. Il s'agit donc de définir la distance entre un individu et tout sous-ensemble de Ω .

III.4.2.2 Evaluation des masses d'évidence à partir d'histogrammes de niveaux de gris et des fonctions d'appartenance

La définition des fonctions de masse dans [Bloch 1996 b] a été effectuée au niveau pixel et les fonctions de masses proposées sont des fonctions trapézoïdales simples dérivées des histogrammes de niveaux de gris et normalisées. Les éléments focaux ont été déduits des informations de l'image et les masses ont été distribuées sur les éléments focaux d'une manière très simple.

Dans [Aurdal 1997], l'auteur s'est intéressé en particulier au passage des niveaux de gris vers les fonctions d'appartenance. Il a proposé une nouvelle méthode adaptée pour la classification de régions homogènes afin de définir pour chaque région considérée une fonction d'appartenance pour chaque classe d'intérêt. Le premier critère que la fonction d'appartenance doit vérifier est basé sur la ressemblance entre l'histogramme des niveaux de gris et la fonction d'appartenance. Le deuxième critère se base sur l'information à priori de la forme attendue des fonctions d'appartenance afin de traiter les problèmes des fréquences faibles. Les fonctions d'appartenance ont été choisies pour être trapézoïdales. Des travaux similaires sont aussi apparus dans [Bloch et al. 1997]. Dans plusieurs travaux les fonctions de masse ont été issues des fonctions d'appartenances et leurs fusions ont été effectuées par l'opérateur orthogonal de Dempster [Aurdal 1997].

III.4.2.3 Evaluation des masses d'évidence à partir de mesures

Dans certains cas, des mesures issues de l'image ou de connaissances expertes peuvent servir pour l'estimation des fonctions de masse [Milisavljevic et Bloch 2003]. Dans le travail décrit dans [Taleb-Ahmed et al. 2002] et qui se réfère à des images médicales, il s'agit de prendre une décision sur l'appartenance de chacun des points au cortical osseux. Pour chaque point du contour d'une coupe de la colonne vertébrale, des mesures et des connaissances à priori sont disponibles. La modélisation passe par la définition d'une distribution de masse d'évidence dépendante de ces mesures. En effet, un certain nombre d'informations de type numérique peuvent être exploitées pour un point quelconque :

- le niveau de gris. Ce paramètre a été utilisé dans l'algorithme du contour actif.
- la moyenne et l'écart-type de niveau de gris sur un voisinage du snaxel étudié.
- la distance $d(P_i, Q_i)$ qui sépare deux points appariés P_i et Q_i : distance entre les contours détectés des deux coupes successives (P, Q)

Le cadre de discernement considéré dans [Taleb-Ahmed et al. 2002] est $\Omega = \{\text{peau, corps vertébral, cortical osseux, muscle, air, graisse, fluide, mélange}\}$. Sur chacune des coupes parallèles de la colonne vertébrale, une segmentation par contour actif a été réalisée.

Dans [Royère et al. 2003], l'élaboration de fonctions de croyance à partir de données SIG et GPS a été faite en utilisant des mesures géométriques. Les critères utilisés sont :

- la proximité
- le cap
- la vitesse

Dans [Tangestani et Moore 2002], le calcul des fonctions de masses s'est basé sur des informations issues des cartes de la région et sur des données subjectives.

III.4.2.4 Estimation des fonctions de masse avec l'utilisation de l'information contextuelle

L'information contextuelle est exploitée dans la plupart des nouveaux travaux de classification basée sur la théorie des fonctions de croyance, dans le but de corriger ou d'ajuster les valeurs des fonctions de masse [Laha et al. 2006]. L'utilisation des champs de Markov est l'un des moyens de prise en compte de l'information contextuelle. D'autres travaux ont exploité les champs de Markov pour l'estimation des fonctions de masse [Ben Djebbour et al. 2001], [Ben Tabet et Maodong 2008], [Ben Tabet et Maodong 2004], [Pieczynski 2004]. En effet, les champs aléatoires de Markov cachés permettent de prendre en compte l'information contextuelle et étaient souvent utilisés dans un contexte bayésien. Dans le contexte de la théorie de l'évidence, l'utilisation des champs de Markov a été exploitée dans [Ben Djebbour et al. 2001] pour proposer des modèles évidentiels et approuver les algorithmes de segmentation basés sur les champs de Markov. Les travaux correspondants ont montré la faisabilité de la fusion évidentielle non supervisée dans un contexte Markovien. Certaines applications des champs de Markov ont été orientées vers une segmentation non supervisée d'images Radar et Spot [Ben Tabet et Maodong 2008].

Dans [Ben Tabet et Maodong 2008], le calcul des fonctions de masse est basé sur l'utilisation d'un sous-mélange de la distribution de Dirichlet « a sub-mixtures of the Dirichlet distribution ». Une extension évidentielle de l'algorithme ICM (~~Iterative Conditional Mode~~—en anglais pour ~~mode conditionnelle itérative~~) [Foucher et al. 2002] nommée EICM a été proposée. L'information contextuelle a été prise en compte en utilisant l'approche ICM qui a été adaptée pour manipuler le cas d'hypothèses composées.

La représentation des connaissances est très importante à ce niveau pour bien modéliser les informations contextuelles à intégrer dans le processus de fusion. Des travaux récents ont eu lieu permettant la représentation des connaissances à travers des Ontologies [Farah et al. 2008c].

III.4.2.5 Estimation des fonctions de masse avec morphologie mathématique

Sans se restreindre à des espaces de représentation de dimension 1, la méthode proposée dans [Bloch 2008] permet de calculer des masses sur des disjonctions par érosions et dilations de masses définies dans un premier temps sur des singletons. Les propriétés de ces opérations morphologiques (en particulier de dualité) permettent de les interpréter comme des croyances et plausibilités, dont les masses sont ensuite déduites

III.5 Conclusion

Ce chapitre nous a permis en premier lieu de définir et présenter les différentes formes d'éléments focaux. L'étude du choix des éléments focaux, de leurs définitions en tant qu'ensembles nets ou sous-ensembles flous dépend de l'application et de la nature de l'information à classer. Ainsi, la présence d'incertitude floue a justifié dans plusieurs travaux la définition d'éléments focaux flous. Ce qui a impliqué dans plusieurs cas d'exemples présentés une estimation des fonctions de masses inspirée des fonctions d'appartenance.

L'insuffisance de certains algorithmes de classification classiques tels que les C-moyennes (en sa version floue : les C-moyennes floues) et les k-plus proches voisins a donné lieu à des approches évidentielles qui en même temps profitent de ces algorithmes pour l'estimation des fonctions de masse qu'ils manipulent et des avantages de la théorie de l'évidence. Les approches markoviennes permettant de prendre en compte l'information contextuelle ont aussi apparues sous la forme évidentielle.

La complexité des calculs de la théorie des fonctions de croyance a aussi été traitée dans ce chapitre du point de vue des travaux existants se basant principalement sur les méthodes simplificatrices d'approximation.

Le problème de la complexité des calculs de la théorie des fonctions de croyance est traité dans le chapitre suivant. Un état de l'art sera présenté suivi de notre solution pour la réduction de la complexité.

CHAPITRE IV

SOLUTIONS PROPOSEES POUR LA REDUCTION DE LA COMPLEXITE

CHAPITRE IV

Solutions proposées pour la réduction de la complexité

IV.1 Introduction

L'application de la théorie des fonctions de croyance pour la fusion des sources d'information a souvent été critiquée à cause de sa complexité temporelle exponentielle. En effet, l'utilisation de cette théorie a recours à des calculs complexes, utilisant l'opérateur de Dempster [Shafer 1990], dont le coût augmente exponentiellement lorsque le nombre de classes et de sources devient important [Barnett 1981].

Nous commençons dans ce chapitre par une présentation du problème combinatoire de la fusion basée sur la théorie de croyance. Ensuite, nous donnons un aperçu général sur les différentes méthodes essayant de réduire cette complexité. Puis, nous décrivons la méthode de réduction de la complexité que nous proposons, en se basant sur une réduction du référentiel de définition. Une étude expérimentale et une évaluation des performances de la méthode proposée sont enfin présentées.

IV.2 Complexité exponentielle de l'application de la fusion par la théorie des fonctions de croyance

La théorie des fonctions de croyance comprend trois types d'opérations : La définition des fonctions de masse pour chaque source, le calcul des fonctions de masse pour la fusion de sources et ce par une règle de fusion (utilisant le plus souvent l'opérateur de Dempster) et enfin la prise de décision. Dans ce qui suit, nous présentons un calcul de la complexité sous-jacente pour chacune de ces étapes.

IV.2.1 Compléxité par source d'information

Une fonction de masse sur un cadre de discernement fini Ω est potentiellement beaucoup plus complexe qu'une mesure de probabilité sur le même cadre. Pour spécifier une mesure de probabilité, on a besoin de $|\Omega|$ nombres (les probabilités pour chaque élément du cadre de discernement), alors que pour spécifier une fonction de croyance, on pourra avoir besoin de calculer $2^{|\Omega|} - 1$ nombres (les masses de croyance pour chaque sous-ensemble non vide du

référentiel de définition), ce qui implique une complexité temporelle exponentielle en fonction du cardinal $|\Omega|$ du cadre de discernement.

IV.2.2 Compléxité de la fusion de sources à travers l'opérateur orthogonal de Dempster

La combinaison orthogonale de Dempster est décrite par l'équation (1.19) (cf. chapitre I) et permet de combiner les fonctions de masse issues de plusieurs sources (deux à deux). Chacun des éléments de la somme calculée dans cette équation est complexe en soi (comme déjà mentionnée dans la section précédente), et le nombre de ses éléments est souvent exponentiel. Nous pouvons en effet constater à partir de l'équation (1.19) que le résultat de la combinaison d'une fonction de masse avec r éléments focaux et une fonction de masse avec s éléments focaux sera une fonction de masse avec $r*s$ éléments focaux. Ainsi, nous pouvons obtenir une fonction de masse d'évidence très complexe en combinant un nombre modéré de fonctions de masse qui ne sont pas individuellement complexes.

Les croyances à combiner sont généralement définies initialement sur des cadres de discernement différents. Ainsi, il faut chercher une manière d'unifier ces cadres. En appliquant cette unification en présence de différentes sources avec des cadres différents et un grand nombre d'hypothèses, le cadre de discernement devient énorme et ainsi se heurte à un sérieux problème de complexité [Haenni et Lehmann 2002], [Haenni et Lehmann 2003], [Shafer 1990].

IV.2.3 Prise de décision

Comme déjà mentionné dans le chapitre I (cf. section I.4.3), la décision est prise en maximisant les fonctions de crédibilité, de plausibilité ou de probabilité pignistique (cf. équations respectives (1.17), (1.18) et (2.3)). Chacune de ces équations nécessite un calcul de complexité exponentielle de l'ordre de $2^{|\Omega|}$.

IV.3 Etat de l'art des approches de réduction de la complexité

Plusieurs approches de la littérature ont essayé de réduire la complexité exponentielle des différentes étapes de la théorie de croyance explicitées précédemment, notamment les deux premières étapes. Nous présentons dans cette section les principes généraux des principales approches ayant trait à ce problème de réduction de complexité, avant de proposer notre propre solution dans une prochaine section.

Nous présentons dans cette section quelques approches essayant de résoudre le problème de complexité exponentielle de l'utilisation de la théorie des fonctions de croyance dans la fusion. Certaines de ces approches visent à simplifier les calculs des fonctions de masses, tandis que d'autres se basent sur des techniques d'approximation qui réduisent de différentes manières le nombre d'éléments focaux.

IV.3.1 Algorithme de Barnett

Barnett [Barnett 1981] a proposé des algorithmes pour résoudre partiellement le problème de complexité issu de l'application de la règle de Dempster pour le cas spécial dans lequel chaque fonction de croyance soutient un élément focal simple (singleton de Ω) ou le complément d'un élément simple. Ces algorithmes sont linéaires plutôt qu'exponentiels en fonction de la taille du cadre de discernement, ce qui réduit la complexité des calculs de la règle de Dempster par rapport au cas général.

IV.3.2 Transformation rapide de Möbius

Il a été démontré que la complexité de la règle de Dempster peut être réduite même dans le cas général, parce qu'une grande partie du calcul pour chaque sous-ensemble est répétée. En effet, Thoma [Thoma 1989] a montré comment on peut éliminer cette répétition par une transformation rapide de Möbius, qui permet de retrouver la masse à partir de la fonction de crédibilité. Cependant, la faisabilité de cette idée au niveau pratique, reste à vérifier [Denoeux et Ben Yaghlane 2002].

IV.3.3 Propagation dans les arbres

Afin de réduire la complexité de l'application de la théorie des fonctions de croyance à la fusion de sources d'informations, certains auteurs ont opté pour une représentation du problème par des hypergraphes ou plus particulièrement par des arbres de jointure [Shafer 1990]. Des algorithmes permettant la construction et le parcours d'arbres ont été réalisés. Un des plus connus est l'algorithme de fusion de Shenoy conçu pour la construction de l'arbre et la propagation dans l'arbre simultanément [Shenoy1992]. Les nœuds de l'arbre sont les éléments d'évidence et les liens entre les nœuds forment le chemin permettant de passer l'information entre les nœuds à travers des messages qui sont les fonctions de croyances.

IV.3.4 Méthodes d'approximations

Les algorithmes de réduction du temps de calculs proposés dans la littérature [Kennes 1992], [Thoma 1989] sont principalement développés pour des situations particulières telles que le cas où les fonctions de croyance soutiennent un élément focal simple (cas de l'algorithme de Barnett par exemple). Cependant, le temps de calcul d'une combinaison de deux fonctions de masses m_1 et m_2 issues de deux sources S_1 et S_2 est souvent fortement lié aux nombres d'éléments focaux que les fonctions m_1 et m_2 possèdent. D'où, certains auteurs ont envisagé d'approximer les fonctions de masse m_1 et m_2 par des fonctions de masse m_1' et m_2' , possédant un nombre d'éléments focaux plus faible [Orponen 1990]. Ainsi deux techniques d'approximations existent : une première permet de réduire le nombre d'éléments focaux alors que la deuxième permet d'approximer les fonctions de masses par d'autres ayant un nombre d'éléments focaux plus faible.

IV.3.4.1 Réduction du nombre d'éléments focaux

La réduction du nombre d'éléments focaux ef_i s'est généralement faite par agrégation, sommation ou élimination d'éléments focaux, avant ou après l'étape de combinaison des masses de croyance. Certaines approches éliminent les éléments focaux peu significatifs c'est-à-dire de poids $m(ef_i)$ faible. Les paramètres pouvant intervenir dans la sélection sont le pourcentage total de poids des éléments focaux conservés et le nombre minimal et /ou maximal d'éléments focaux. La réduction du nombre d'éléments focaux suite à l'estimation préalable des fonctions de masse nécessite une redistribution des masses d'évidence pour assurer de nouveau la condition de normalisation (somme des masses égale à 1) [Bauer 1997].

IV.3.4.2 Méthodes d'approximation des fonctions de masses de croyance

L'approximation des fonctions de masses de croyance (nette ou floue) peut être réalisée à travers des calculs d'approximations inférieures et supérieures. La détermination de ces approximations se base sur des méthodes de passages des fonctions de croyance vers des fonctions de possibilités (ou de nécessités) [Denœux 2001]. En effet, il a été démontré que l'approximation d'une paire (Cr, Pl) par une paire (N, Π) est possible à travers la définition des approximations intérieures et des approximations extérieures du couple (Cr, Pl) [Dubois et Prade 1994]. Un couple (N, Π) définit une approximation intérieure de (Cr, Pl) si et seulement si pour tout $A \subseteq \Omega$, on a $\Pi(A) \leq Pl(A)$ (ou d'une manière équivalente, $Cr(A) \leq N(A)$). Inversement, un couple (N, Π) définit une approximation extérieure de (Cr, Pl) si et seulement si pour tout $A \subseteq \Omega$, $\Pi(A) \geq Pl(A)$ (ou d'une manière équivalente, $Cr(A) \geq N(A)$).

L'algorithme proposé dans [Dubois et Prade 1994] permet à chaque étape de fusionner deux éléments focaux, et la masse est transférée à leur intersection ou à leur union. Les approximations résultantes permettent le calcul des limites inférieures et supérieures des fonctions de crédibilité et de plausibilité induites par la somme conjonctive ou disjonctive des fonctions de masses de croyance.

Dans [Petit-Renaud 1999], une autre méthode d'approximation est introduite afin de contrôler la complexité au cours de la phase de combinaison. Il s'agit d'une méthode de simplification d'une fonction de croyance quelconque (nette ou floue) se basant sur la réduction du nombre d'éléments focaux pendant la combinaison des fonctions de croyance avec le principe suivant. Soient deux fonctions de masse de croyance m_1 et m_2 ayant respectivement p et q éléments focaux, et m_{12} leur fonction de masse de croyance combinée. Avant de combiner m_{12} avec une troisième masse de croyance m_3 , l'auteur procède à la réduction du nombre d'éléments focaux de m_{12} en créant une fonction de masse de croyance approchée $m'_{12} = App(m_{12})$.

Il est à noter que les méthodes de détermination ou d'approximation des éléments focaux que nous venons de présenter ont le même inconvénient, qui consiste à déterminer les éléments

focaux (ou à se restreindre à un nombre approximatif d'éléments) suite aux calculs des fonctions de masse par source. Le problème de ces méthodes est qu'elles se réfèrent à l'approximation elle-même qui tolère des erreurs conséquentes expliquées par les calculs approchés et l'élimination de certains éléments focaux.

Nous proposons dans ce qui suit une nouvelle méthode de réduction du temps de calcul, qui consiste à déterminer les éléments focaux dans une étape préalable aux calculs (ou estimations) des fonctions de masse.

IV.4 Solution proposée pour la réduction de la complexité

Dans la théorie des fonctions de croyance, le calcul des fonctions de masse (mono-source et multi sources après combinaison) se trouve contraint par un nombre important d'opérations dépendant du nombre de classes et du nombre de sources à fusionner.

Nous proposons dans cette section notre solution de réduction de la complexité exponentielle du problème de fusion de sources d'information basée sur la théorie des fonctions de croyance, pour une application orientée classification multi-sources d'images de télédétection. Cette solution se décompose en deux étapes. La première étape consiste à réduire le référentiel de définition [Ben Dhiab et al. 2007 a], [Ben Dhiab et al. 2007 b], [Ben Dhiab et al. 2008 a] et la deuxième étape permet de choisir un sous-ensemble de sources à combiner parmi les sources de départ et d'écartier les autres et ceci en se basant sur l'information contextuelle [Ben Dhiab et al. 2008 b].

IV.4.1 Réduction du référentiel de définition

Dans la théorie des fonctions de croyance, le raisonnement porte sur le référentiel de définition 2^Ω . En pratique, le nombre d'éléments focaux est considérablement inférieur à la taille du référentiel de définition à savoir $2^{|\Omega|}$. Nous proposons de réduire le référentiel de définition exclusivement à l'ensemble des éléments focaux avant l'étape d'estimation des masses.

IV.4.1.1 Principe

Pour chaque classe $C_i \in \Omega$ ($i \in \{1, \dots, k\}$ où $k = |\Omega|$), représentée par un ensemble d'échantillons (ou zones d'apprentissage), on définit la fonction histogramme $h_{C_i} : [0, 255] \rightarrow \mathbb{N}$, qui associe à chaque valeur x , le nombre $h_{C_i}(x)$ d'apparitions de cette valeur dans l'ensemble d'échantillons de la classe C_i considérée. Ainsi, nous considérons qu'une classe C_i (c'est-à-dire un élément singletons de 2^Ω), pour un donné, est un élément focal si elle vérifie l'équation (4.1) suivante :

$$h_{C_i}(x) > 0, \forall C_i \in \Omega \quad (4.1)$$

Pour la recherche des éléments focaux composés, nous déterminons pour chaque événement (ou hypothèse composée) A , l'histogramme h_A associé. Cet histogramme est construit par les bornes inférieures de tous les histogrammes h_{C_i} des classes C_i incluses dans A , i.e. $h_A(x) = \min_{C_i \subset A, i \in \{1, \dots, k\}} (h_{C_i}(x))$.

Ainsi, nous considérons en premier lieu qu'un événement A est un élément focal (composé), pour un x donné, s'il vérifie l'inéquation (4.2) suivante :

$$h_A(x) > 0 \quad (4.2)$$

IV.4.1.2 Extension par seuillage

Un seuillage peut être effectué afin de ne considérer que les éléments focaux les plus significatifs. Nous proposons deux manières d'effectuer ce seuillage.

La première consiste à considérer pour chaque niveau de gris x , uniquement les événements (hypothèses composés) A dont l'histogramme est supérieur à un certain seuil β , choisi d'une manière empirique selon le cas d'application. Cette condition est représentée par l'inéquation (4.3) suivante :

$$h_A(x) = \min_{C_i \subset A, i \in \{1, \dots, k\}} (h_{C_i}(x)) > \sigma \quad (4.3)$$

La deuxième méthode de seuillage consiste à ne retenir dans l'ensemble des éléments focaux, que les événements A telle que la surface de chevauchement entre les histogrammes de leurs différentes « sous-classes » C_i , est supérieure à un seuil σ .

Le seuil peut être choisi, par exemple, comme un facteur de la surface de chevauchement entre les histogrammes des différentes classes composant l'événement A . Dans ce cas, ce seuil s'écrit : $\sigma = p \times (\min_{C_i \subset A, i \in \{1, \dots, k\}} (surface(h_{C_i})))$, où p le pourcentage de la plus petite surface d'histogramme parmi les histogrammes des différentes classes (de l'événement A) en chevauchement. Ce choix de seuil a donné des résultats prometteurs.

Nous retenons ainsi comme éléments focaux composés ceux obéissant aux équations (4.4) suivante :

$$\sum_{x \in [0, \dots, 255]} h_A(x) > p \times (\min_{C_i \subset A, i \in \{1, \dots, k\}} (surface(h_{C_i}))) \quad (4.4)$$

Sachant que le calcul de la surface de l'histogramme d'une classe C_i obéit à l'équation (4.5) suivante :

$$surface(h_{C_i}) = \sum_{x \in [0, \dots, 255]} h_{C_i}(x) \quad (4.5)$$

Nous proposons ainsi de déterminer l'ensemble des éléments focaux à partir des chevauchements des histogrammes de classes comme décrit ci-dessus, en considérant un seuillage approprié. L'ensemble obtenu forme le référentiel de définition qu'on se propose de retenir pour les calculs ultérieurs des fonctions de masses. On notera F ce référentiel de définition réduit. Ainsi, $|F|$ est le nombre d'éléments focaux formant ce référentiel.

IV.4.1.3 Exemple illustratif de la réduction du référentiel de définition

La figure IV.1 illustre la détermination des histogrammes des unions de classes pour un exemple de cadre de discernement $\Omega = \{C_1, C_2, C_3, C_4\}$. Dans la figure IV.1.(a), nous traçons les histogrammes correspondant à des zones d'apprentissages choisis sur une image à 4 classes. Un zoom est fait sur une partie de la figure IV.1. (a) pour illustrer les chevauchements entre les histogrammes des classes C_2 , C_3 et C_4 . Les figures IV.1.(b), (c), (d), (e) et (f) illustrent l'obtention des histogrammes des éléments focaux composés $C_1 \cup C_3$, $C_2 \cup C_4$, $C_2 \cup C_3$, $C_3 \cup C_4$ et $C_2 \cup C_3 \cup C_4$ respectivement. Ainsi, en partant d'un ensemble de définition $\Omega = \{C_1, C_2, C_3, C_4\}$ et considérons les chevauchements entre histogrammes, nous obtenons le référentiel de définition : $F = \{C_1, C_2, C_3, C_1 \cup C_3, C_2 \cup C_3, C_2 \cup C_4, C_3 \cup C_4, C_2 \cup C_3 \cup C_4\}$.

IV.4.1.4 Gain en complexité

Gain au niveau d'une source

Grâce à la réduction du référentiel de définition proposé, il ne s'agit plus d'estimer, pour la source considérée, $2^{|\Omega|} - 1$ masses d'évidence mais seulement $|F|$ masses avec $|F|$ très inférieure à $2^{|\Omega|}$ en pratique.

Gain au niveau de la combinaison de sources

Soient F_1 et F_2 les référentiels de définition réduits de deux sources S_1 et S_2 . La fusion de ces deux sources combine les masses des éléments focaux deux à deux via l'opérateur orthogonal de Dempster. On obtient des masses combinées pour les éléments d'intersections de $|F_1|$ et $|F_2|$ ce qui coûte au pire des cas de l'ordre de $|F_1| \times |F_2|$ opérations arithmétiques. Cette opération de combinaison nécessite dans le cas général de l'ordre de $(2^{|\Omega|})^2$ opérations. L'étape de réduction du référentiel de définition par détermination des éléments focaux proposée, nous fait gagner un nombre d'opérations de l'ordre de $((2^{|\Omega|})^2 - |F_1| \times |F_2|)$ opérations pour une seule opération de combinaison orthogonale.

Le référentiel de définition F_{12} obtenu suite à cette fusion aura un cardinal plus petit que celui de F_1 et F_2 . La nouvelle fusion avec une autre source S_3 coûte de l'ordre de $|F_{12}| \times |F_3|$ opérations. En total, le nombre d'opérations de la combinaison de n sources est majoré par $(n \times \max_{i \in [1, n]} |F_i|^2)$, ce qui est en pratique nettement plus petit que $(n \times (2^{|\Omega|})^2)$.

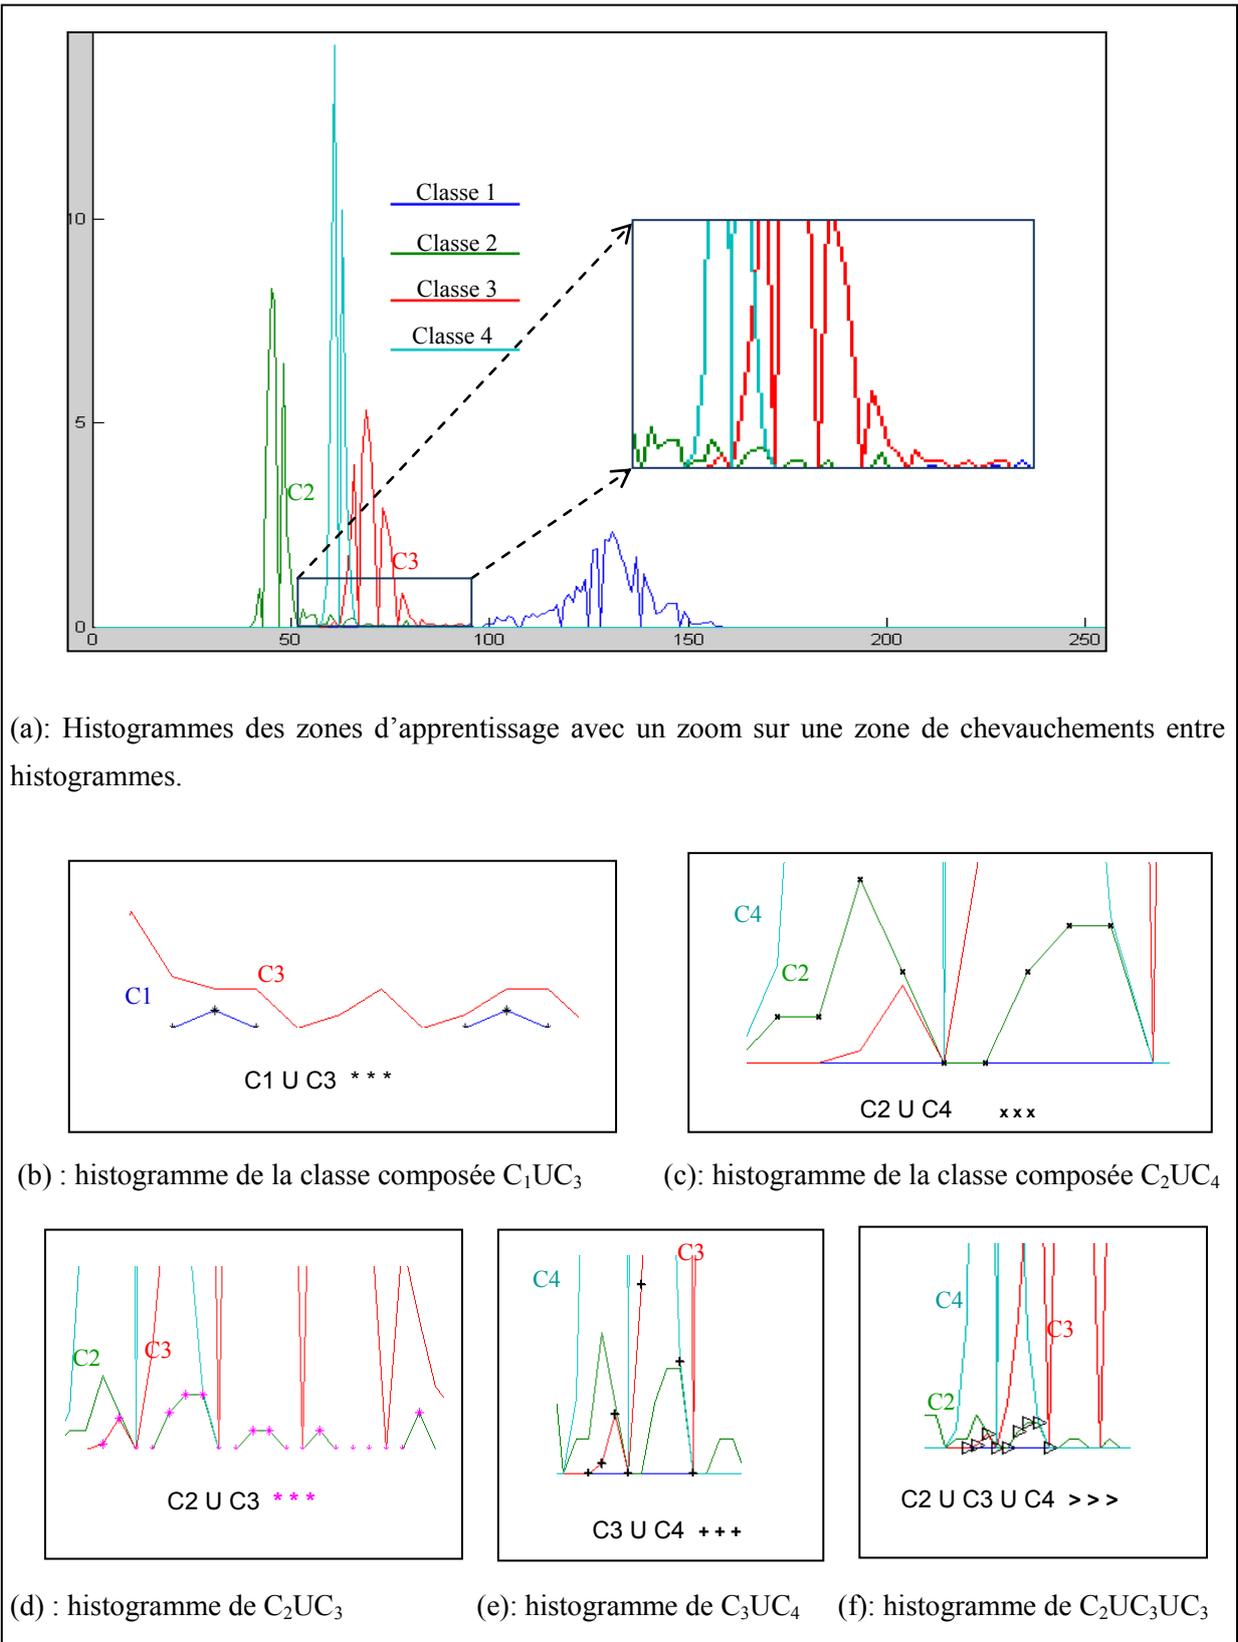


Figure IV.1. Détermination des histogrammes des éléments focaux composés

IV.4.2 Choix contextuel des sources

L'analyse du conflit résultant de la combinaison de toutes les sources fait apparaître une forte corrélation avec le contexte. Souvent, l'implication d'une source d'information dans un processus de fusion dégage des performances contradictoires selon des cas d'utilisation différents. Ceci s'explique par le fait que la fiabilité de l'information fournie par une source est fonction de variables contextuelles, ainsi, la prise en compte du contexte permettra de réduire à la fois ce conflit et aussi la complexité des calculs des masses combinées. Nous proposons dans cette section d'étudier cette alternative de sélection des sources à combiner selon le contexte.

IV.4.2.1 Principe

La première étape des méthodes de fusion de sources d'informations consiste à choisir en premier lieu l'ensemble des sources d'informations à combiner et les hypothèses de l'ensemble de définition à considérer tout au long du processus de fusion. Dans la section précédente, nous avons traité le volet réduction du référentiel de définition, ce qui nous a permis de diminuer considérablement la complexité du système de fusion. Dans cette section, nous présentons un nouveau point de vue qui s'intègre dans la gestion du conflit entre sources et qui diminue à son tour la complexité puisqu'il s'agit pour chaque contexte d'écarter certaines sources et de ne considérer qu'un sous-ensemble de sources, validé par des variables contextuelles que l'on fait intervenir.

La définition d'un sous ensemble de sources correspondant à un contexte dépend de l'application. Pour notre cas, on fera intervenir des règles expertes qui à travers l'évaluation d'un certain nombre de propriétés inhérentes à l'événement A déduisent le sous ensemble SS_i associé. Le diagramme de la figure IV.2 illustre un l'enchaînement de phases d'un processus de fusion basée sur un choix contextuel de sources. Ainsi, l'estimation des fonctions de masses de croyance se fait selon le contexte.

Nous considérons dans la suite notre ensemble de n sources d'informations $S = \{S_1, \dots, S_i, \dots, S_n\}$. Soit z_j une variable contextuelle (avec $j \in \{1, \dots, l\}$) et Z l'espace contextuel décrit par l valeurs. $CS_i \subset Z$ désigne le sous ensemble de Z pour lequel la source S_i serait retenue dans le calcul de la masse combinée.

Chaque jeu de données propre à chaque source n'est pas exploitable en tant que tel, notamment si l'information est imparfaite et ne donne qu'un aspect de la réalité. Une étape importante dans le processus de fusion consiste à modéliser et évaluer la connaissance apportée par chaque source. L'application de la fusion contextuelle pour la classification d'images de télédétection prend une dimension importante du fait qu'elle peut éviter l'implication d'une source dont la fiabilité n'est justifiée que pour des conditions particulières que l'on peut cerner à travers l'évaluation du contexte spécifique.

L'exemple suivant peut être retenu pour expliquer la corrélation qui existe entre la fiabilité

d'une source et le contexte propre d'application :

Soient P un point appartenant à la zone d'étude, S_1 la source image HR, S_2 la source Holder correspondante à S_1 , S_3 l'image des couronnes déduite à partir de S_1 , S_4 l'inventaire forestier numérisé et S_5 le modèle numérique du terrain. Pour chacune de ces sources, on définit une fonction de masse appropriée.

On suppose que l'estimation de la fonction de masse à partir de la source S_5 est basée sur des règles expert qui ne prend en considération que des hypothèses sur des masses d'évidence pour des classes d'espèces forestières calculées en fonction des altitudes.

Soit $\text{foret} : \{C_1, C_2, C_4, C_7\}$ l'ensemble des classes des espèces forestières et Seuil_foret le minimum des limites inférieures des histogrammes de l'ensemble forêt dans la source S_1 .

Si le niveau de gris du point P dans la source S_1 est inférieur à Seuil_foret , on peut considérer qu'on ne se situe pas dans un contexte d'espèces forestières qui ont une activité calorifique importante (donc un niveau de gris assez élevé). Ainsi, la source S_5 peut être écartée dans le calcul de la masse de fusion puisque la masse estimée à partir de cette source n'est fiable que pour l'ensemble des classes forêt. En effet, l'apport du MNT pour ce contexte n'est pas significatif et son élimination dans le calcul de la masse de fusion permet de réduire la complexité de calcul.

<i>Ensemble S des sources</i>
$S_1 \dots S_i \dots S_n$
<i>Détermination du contexte</i>
$SS_1 \dots SS_i \dots SS_m$
<i>Détermination des éléments focaux et des distributions de masses par source</i>
$ F_1 \dots F_i \dots F_m $ $m^{SS_1}(\cdot) \dots m^{SS_2}(\cdot) \dots m^{SS_m}(\cdot)$
<i>Combinaison des masses</i>
$m^{SS_{1,2,\dots,m}}(\cdot)$
<i>Décision</i>

Figure IV.2. Architecture d'un processus de fusion basé sur un choix contextuel de sources

IV.4.2.2 Gain en complexité

Nous basculons ici d'un nombre de sources n à un nombre n' de sources variable par contexte, mais toujours inférieur ou égale à n . Ainsi, le nombre de combinaisons des sources 2 à 2, dans le cas d'utilisation de l'opérateur orthogonal de Dempster, diminue de $(n-1)$ à $(n'-1)$. Ceci se répercute clairement la complexité calculée dans la section IV.4.1.4 et n sera alors remplacée par n' qui peut être nettement inférieur à n dans beaucoup de cas d'application.

IV.5 Etude expérimentale et évaluation des performances

Nous présentons dans cette section deux exemples permettant d'illustrer la réduction de complexité de l'approche proposée, consistant à réduire le référentiel de définition. Une étude expérimentale plus complète sera présentée dans un chapitre VI.

Exemple 1 :

Soit l'exemple d'un cadre de discernement correspondant à une image haute résolution d'une fenêtre de notre zone d'étude. Avec : $\Omega = \{C_1, C_2, C_3, C_4, C_5\}$; $2^{|\Omega|} - 1 = 2^5 - 1 = 31$.

Les classes ont été choisies sur la base de l'inventaire forestier de la façon suivante :

C_1 = Chêne Zen ; C_2 = Sol très peu couvert (sol nu) ; C_3 = Arboretum ; C_4 = Chêne Liège ; C_5 = Zone urbaine (sol nu).

Outre les chevauchements importants entre les histogrammes des zones d'apprentissages correspondants à ces classes et illustrés par la figure IV.3, nous remarquons des chevauchements de très petite taille comme illustré par les figures IV.4 et IV.5. Ces derniers chevauchements correspondent à des hypothèses composées que nous considérons non pertinentes par opposition à celles correspondantes aux chevauchements importants (exemple chevauchements « importants » entre C_1 et C_2 ou entre C_1 et C_3). En prenant un seuil calculé avec pourcentage p égal à 0.1 (cf. équation 4.4), nous obtenons la figure IV.6 dans laquelle nous basculons du référentiel de définition initial de cardinal 31 à un nouveau référentiel de définition de taille 14.

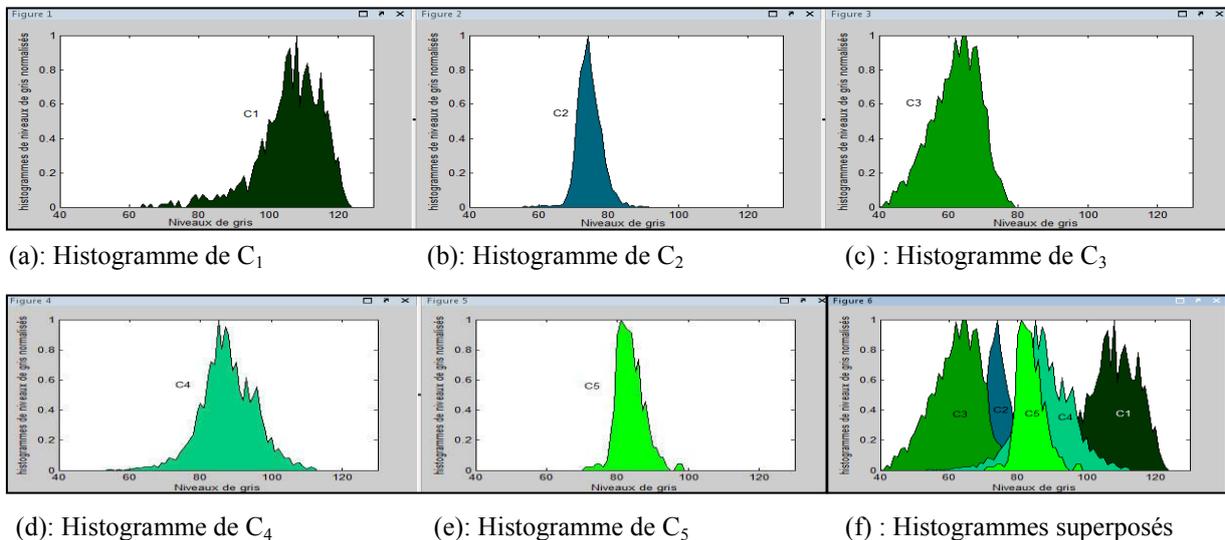


Figure IV.3. Histogrammes des classes des zones d'apprentissages de la fenêtre 1 de l'IHR.

Dans la figure V.6, les chevauchements entre C_1 et C_2 et entre C_1 et C_3 sont occultés par d'autres histogrammes. Nous illustrons les chevauchements occultés dans une figure séparée (figure IV.7).

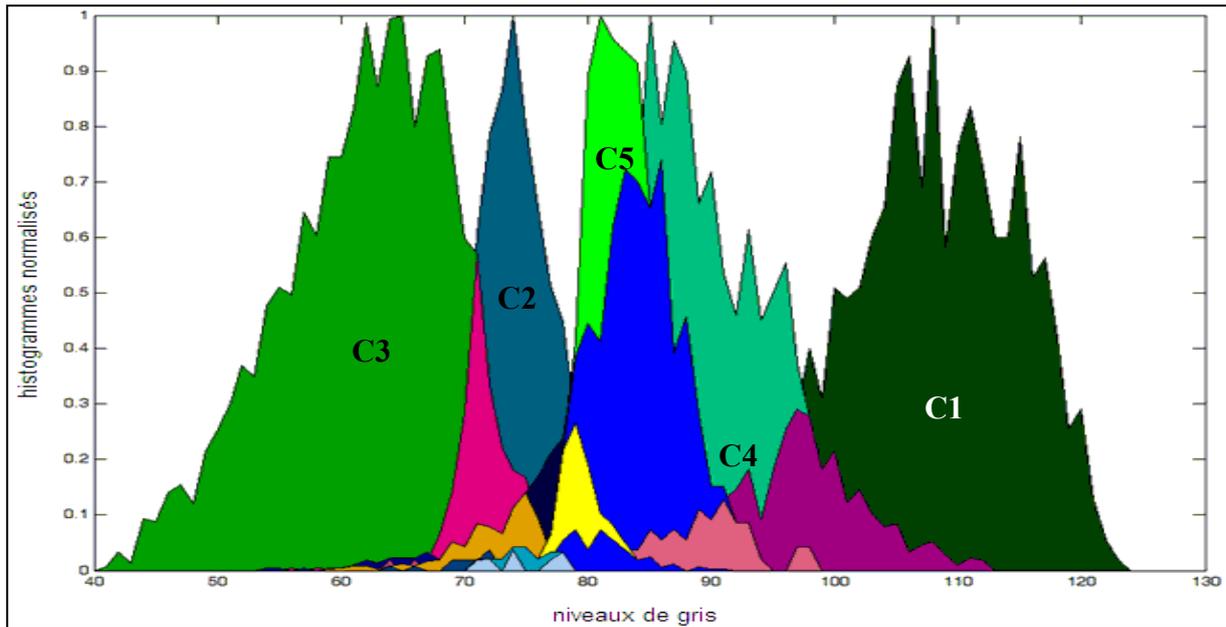


Figure IV.4. Histogrammes des classes des zones d'apprentissage et leurs chevauchements

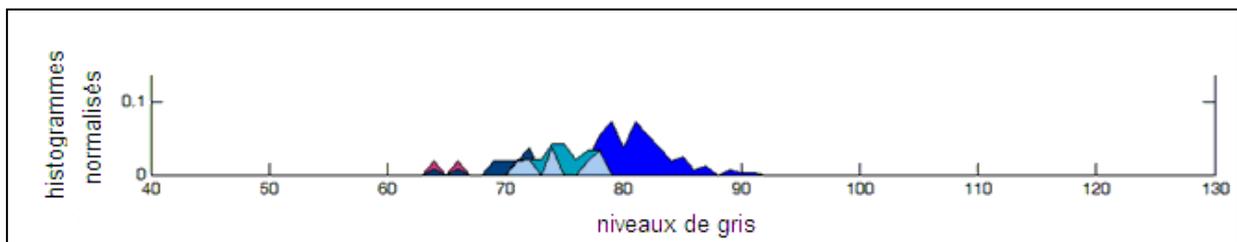


Figure IV.5. Chevauchements mineurs entre les histogrammes (normalisés) des classes.

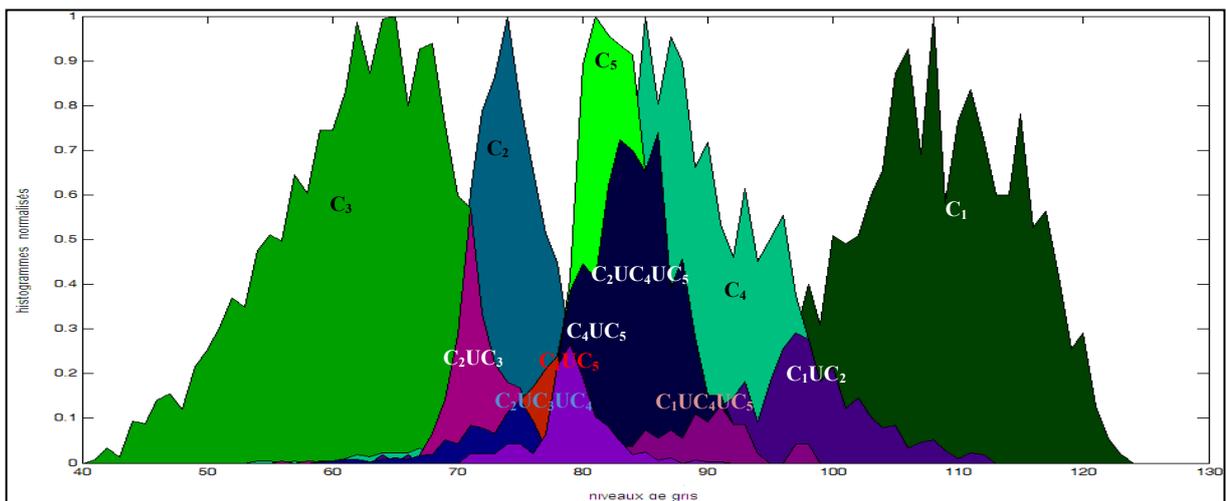


Figure IV.6. Histogrammes des classes des zones d'apprentissage et leurs chevauchements pour $p=0.1$.

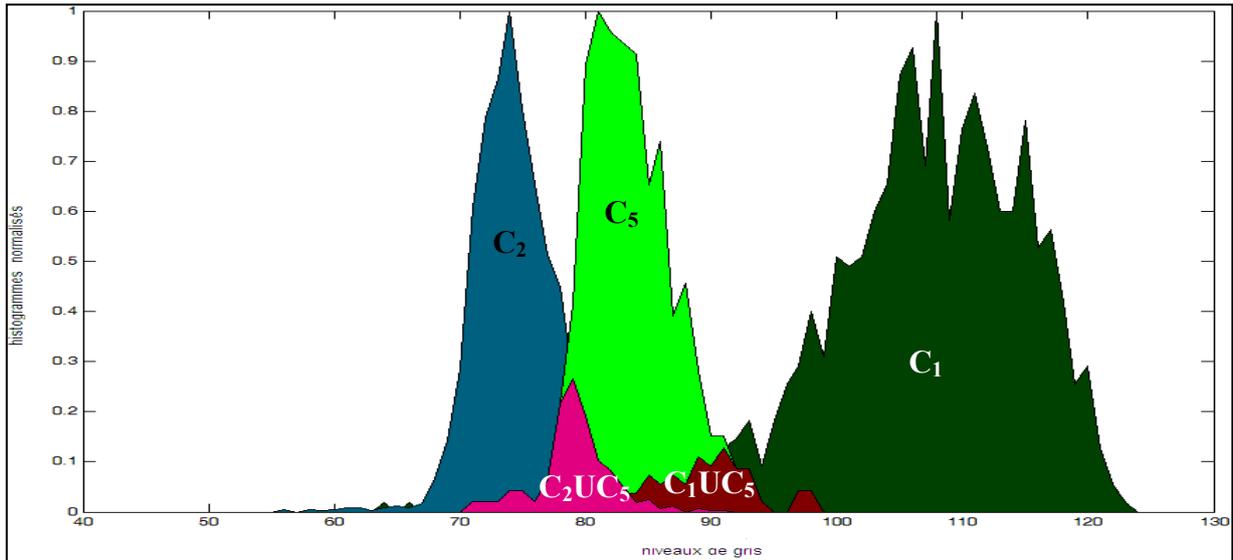


Figure IV.7. Histogrammes de classes occultées dans la figure IV.6.

En augmentons le seuil avec un pourcentage p égal à 0.2, nous obtenons un référentiel de définition à 9 classes : 5 classes singletons et seulement 4 classes composées. La figure IV.8 illustre l'évolution du nombre de classes en fonction du rapport de surface de chevauchement entre les histogrammes des classes en variant progressivement ce rapport.

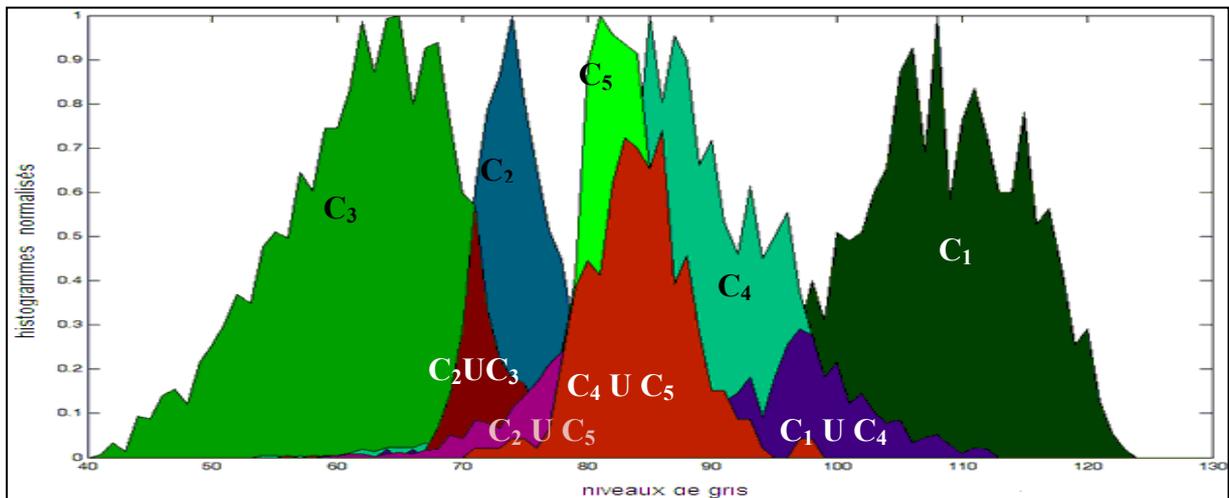


Figure IV.8. Histogrammes des classes des zones d'apprentissage et leurs chevauchements pour $p=0.2$.

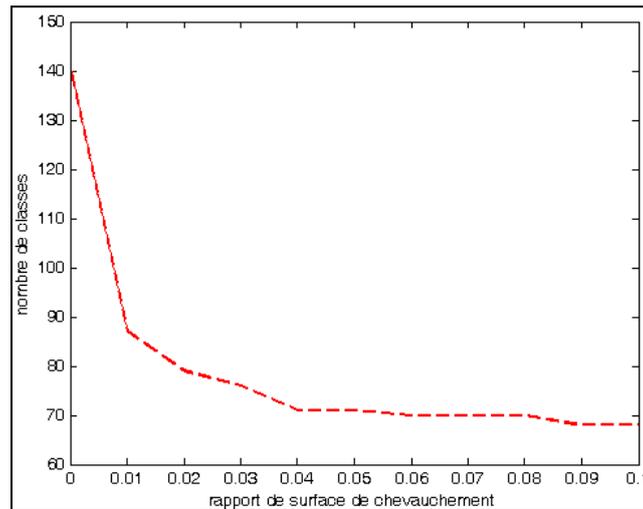


Figure IV.9. Evolution du nombre de classes en fonction du rapport de surface de chevauchement.

Exemple 2 :

Nous passons à un deuxième exemple pour une image moyenne résolution. Le choix des zones d'apprentissages est illustré par la figure IV.10. Le cadre de discernement correspondant est :

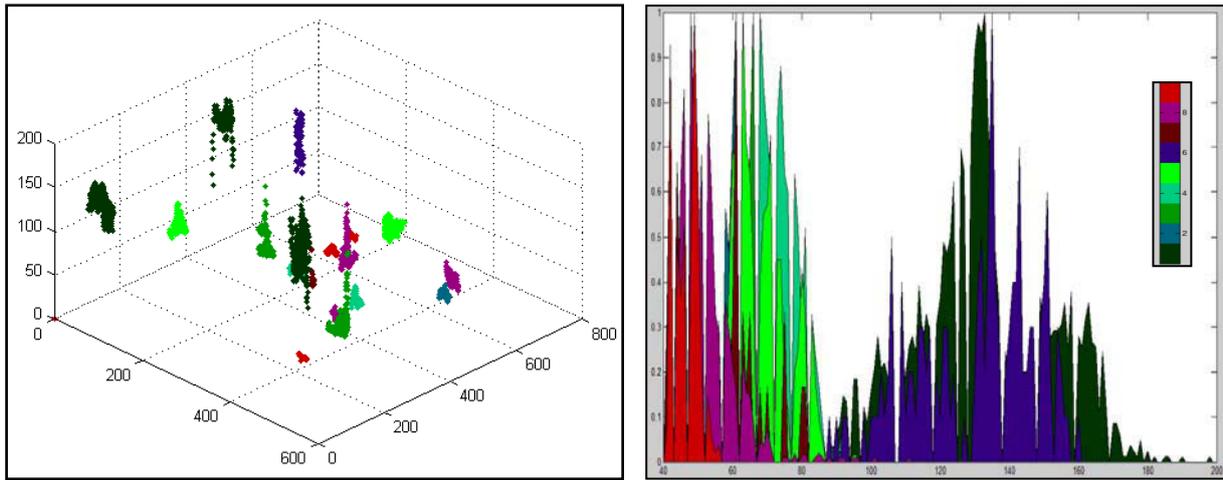
$$\Omega = \{C_1, C_2, C_3, C_4, C_5, C_6, C_7, C_8, C_9\}; \quad 2^{|\Omega|} - 1 = 2^9 - 1 = 511.$$

Les classes ont été choisies sur la base de l'inventaire forestier de la manière suivante :

C_1 = Sol nu ; C_2 = pins divers ; C_3 = Chêne liège ; C_4 = Chêne vert ; C_5 = Chêne zen ;
 C_6 = Cypres ; C_7 = Eucalyptus ; C_8 = Pin Maritime ; C_9 = Pin pignon.

Les confusions entre classes (chevauchements entre les histogrammes des zones d'apprentissages) sont illustrées par la figure IV.11.

Comme le montre la figure IV.12, pour un seuil σ égal à zéro, nous basculons d'un référentiel de définition de taille théoriquement égal à 511 ($2^{|\Omega|} - 1$) à 140 éléments focaux seulement ($|F|=140$). En variant le seuil nous arrivons jusqu'à $|F|=69$ éléments focaux pour $p = 0.1$.



(a): Nuage des points des zones d'apprentissages (b): Histogrammes superposés des classes de Ω

Figure IV.10. Choix des zones d'apprentissages des classes de Ω et histogrammes superposés de ces zones pour l'IMR.

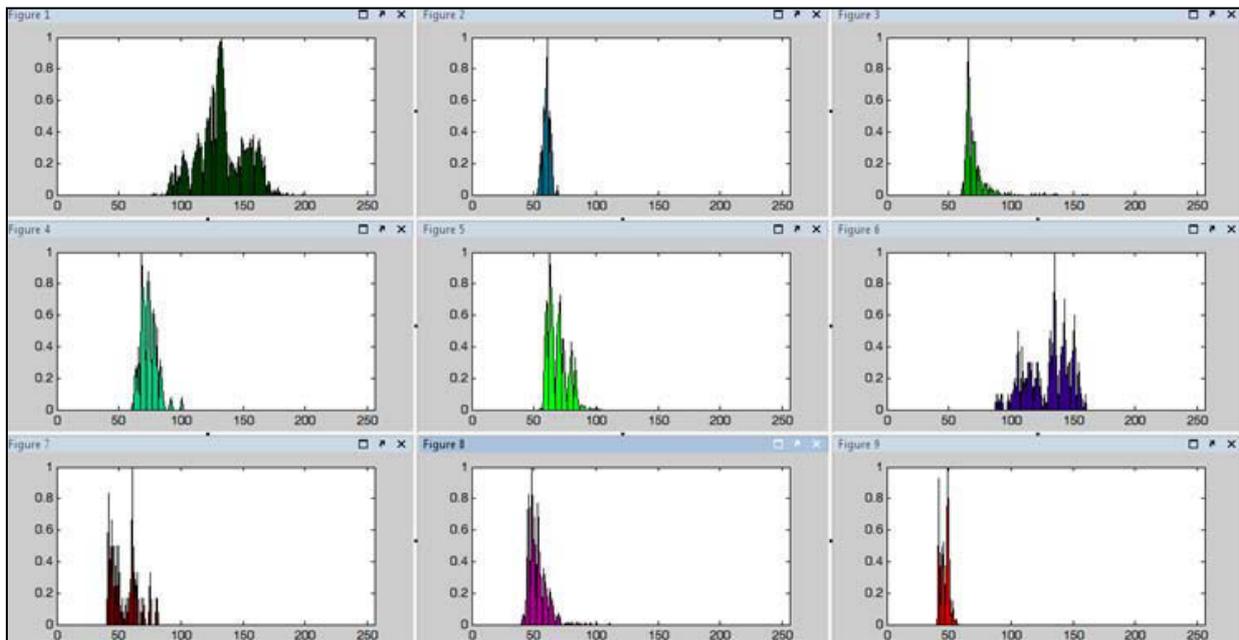


Figure IV.11. Histogrammes des zones d'apprentissages des classes de Ω pour l'IMR.

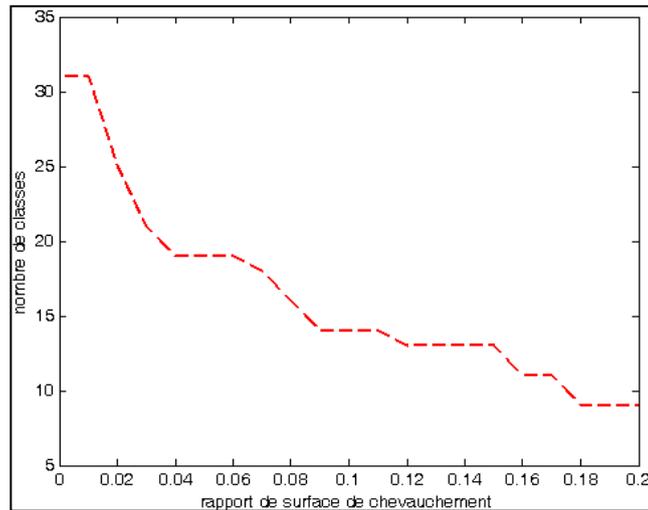


Figure IV.12. Evolution du nombre de classes en fonction du rapport de surface de chevauchement pour l'exemple de l'IMR

IV.6 Conclusion

Dans ce chapitre, nous nous sommes intéressés au problème de la complexité exponentielle de la fusion par la théorie des fonctions de croyance. Nous avons étudié les principales approches de la littérature visant à réduire cette complexité, et nous avons ensuite proposé notre propre solution se basant sur la réduction du référentiel de définition. Cette méthode permet de se limiter uniquement aux éléments focaux dans le calcul des masses d'évidence. Nous avons évalué théoriquement le gain de complexité de notre méthode, et ce pour les trois niveaux sur lesquels elle agit, à savoir le gain pour le calcul mono-sources, celui de la fusion multi-sources et enfin la prise en compte du contexte pour le choix des sources. L'étude expérimentale effectuée a montré l'apport de notre méthode dans la détermination et la maîtrise du nombre d'éléments focaux.

CHAPITRE V

ESTIMATION DES FONCTIONS DE MASSE : METHODES ET APPROCHES PROPOSEES

CHAPITRE V

Estimation des fonctions de masse : Méthodes et approches proposées

V.1 Introduction

La classification par la théorie des fonctions de croyance nécessite tout d'abord l'estimation des fonctions de masses pour le calcul des fonctions de crédibilité ou de plausibilité qui en résultent et sur lesquels se base la décision du processus de classification.

Dans le chapitre IV, nous avons proposé des solutions pour résoudre le problème d'explosion combinatoire posé par le calcul des masses des événements composés (unions de classes). Ces fonctions de masses doivent être estimées en fonction de la source et de la nature de l'attribut envisagé pour la masse. Les méthodes d'estimation que nous allons introduire dans les sous section V.2 et V.3 utilisent les histogrammes des classes définies dans la phase d'apprentissage. Ces méthodes peuvent être appliquées aux histogrammes des niveaux de gris et aussi aux histogrammes des exposants de Hölder que nous avons retenu comme attribut de texture. Nous avons envisagé aussi une étape de révision par le contexte. L'application étant faite sur des images forestières, les contextes choisis sont liées aux couronnes d'arbre et à leurs structures.

V.2 Approche spectrale d'estimation des fonctions de masse

Nous proposons, dans cette section, deux méthodes d'estimations des fonctions de masses d'évidence basées sur l'information spectrale [Ben Dhiaf et al. 2007 a]. La première après passage par les distributions de possibilités et la deuxième directement à partir des histogrammes des niveaux de gris.

V.2.1 Méthode d'estimation des fonctions de masse avec passage par les distributions de possibilités

Cette première méthode se résume en deux étapes :

- Calcul de la distribution de possibilités à partir des histogrammes de niveaux de gris des zones d'apprentissage,

- Calcul des fonctions de masses d'évidence à partir des distributions de possibilités ainsi obtenues.

Nous utilisons pour le premier passage, l'approche de Dubois et Prade généralisée par Masson et Denoeux [Denoeux 2005] dans le cas où les probabilités sont inconnues et permettant d'inférer une distribution de possibilité à partir de données expérimentales.

On suppose que les données disponibles consistent en N observations réparties en k classes de Ω suivant une distribution de probabilité IP_X . Soit n_i le nombre d'observations se répartissant dans la $i^{\text{ème}}$ classe C_i . Le vecteur $n = (n_1, \dots, n_k)$ est la réalisation d'une variable aléatoire multinomiale de paramètres $p = (p_1, \dots, p_k)$ où chaque $p_i = IP_X(C_i) > 0$ est la probabilité d'apparition de la $i^{\text{ème}}$ classe (ou proportion de la classe i), avec $\sum_{i=1}^k p_i = 1$.

Cette approche consiste à estimer les p_i à l'aide d'intervalles de confiance simultanés avec un niveau de confiance donné $1 - \alpha$ sur les proportions d'une loi multinomiale, puis à en déduire une distribution de possibilités qui dominera la vraie distribution de probabilité dans au moins $100(1 - \alpha)\%$ des cas. Calculer l'intervalle de confiance $[p_i^-, p_i^+]$ revient à résoudre l'équation (5.1). Cette équation a deux solutions qui définissent les limites inférieures et supérieures de l'intervalle de confiance [Denoeux 2005].

$$p_i^2(N + \chi^2(1 - \alpha, 1)) - (2n_i + \chi^2(1 - \alpha, 1))p_i + \frac{n_i^2}{N} = 0, \forall i = 1, K \quad (5.1)$$

avec $\chi^2(1 - \alpha/k, 1)$: le quantile de niveau $1 - \alpha/k$ d'une distribution du χ^2 à un degré de liberté.

V.2.2 Calcul des distributions de possibilités

Il s'agit de chercher la distribution de possibilités, sur Ω , la plus spécifique dominant toute distribution de probabilité définie par $p_i \in [p_i^-, p_i^+], \forall i$ [Masson et Denoeux 2006]. La solution du problème peut être obtenue de la manière suivante :

Soit P l'ordre partiel induit par les intervalles $[p_i] = [p_i^-, p_i^+]$: tels que $(C_i, C_j) \in P \Leftrightarrow p_i^+ < p_j^-$ et $\Lambda(P) = \{L_l, l = 1, L\}$ l'ensemble de ses extensions linéaires. Pour toute permutation possible σ_l associée à $\Lambda(P)$, et chaque classe C_i , il s'agit de résoudre le programme linéaire suivant (5.2):

$$\pi_i^{\sigma_l} = \max_{p_1, \dots, p_k} \sum_{\{j / \sigma_l^{-1}(j) \leq \sigma_l^{-1}(i)\}} p_j \quad \text{sous les contraintes :} \quad \begin{cases} \sum_{i=1}^k p_i = 1 \\ p_i^- \leq p_i \leq p_i^+ \quad \forall i \in \{1, \dots, k\} \\ p_{\sigma_l(1)} \leq p_{\sigma_l(2)} \leq \dots \leq p_{\sigma_l(k)} \end{cases} \quad (5.2)$$

et retenir la distribution la plus spécifique dominant toutes les distributions π^{σ_l} (5.3) :

$$\pi_i = \max_{l=1, L} \pi_i^{\sigma_l} \quad \forall i \in \{1, \dots, k\} \quad (5.3)$$

Cette étape produit une distribution de possibilités. Ainsi, nous calculons une distribution de possibilité pour chaque élément de F en se basant sur les données expérimentales (les histogrammes h_{ef_i} avec $i \in \{1, \dots, k_nouv\}$).

V.2.3 Calcul des fonctions de masse d'évidence

Soit $F = \{ef_i, i \in \{1, \dots, k_nouv\}\}$ l'ensemble des éléments focaux, de cardinal k_nouv , formé par les événements ef_i de masses non nulles. Ce nouveau cadre de discernement réduit a été déterminé en faisant intervenir les histogrammes des classes de Ω (que nous avons noté h_{C_i}) et les nouveaux histogrammes (h_{A_i}) déduits des chevauchements de ces dernières (On rappelle que h_{A_i} est l'histogramme de A_i obtenu comme détaillé dans le paragraphe V.4 et selon l'équation (5.2)). Nous noterons alors h_{ef_i} l'histogramme d'un élément focal ef_i de Ω' .

Nous avons calculé (dans l'étape précédente) des distributions de possibilités correspondant à chacun de ces histogrammes. Nous pouvons tracer ainsi de nouveaux histogrammes que nous appellerons histogrammes de distribution de possibilités. Notons $\pi_x(C_i)$ et $\pi_x(A_i)$ les distributions de possibilités, pour une mesure x , d'un événement singleton C_i et d'un événement composé A_i respectivement. Ainsi pour chaque mesure x nous associons un vecteur $\pi_x = \{\pi_x(C_1), \dots, \pi_x(C_k), \pi_x(A_{k+1}), \dots, \pi_x(A_{k_nouv})\}$ qu'on pourra écrire aussi en tant que $\pi_x = \{\pi_x(ef_i) / i = 1 \dots k_nouv\}$.

Nous proposons d'estimer les fonctions de masse d'évidence en les déduisant de ces distributions de possibilités. Pour répondre à la contrainte $\sum m(A_i) = 1$, qui pourra être réécrite dans le cas de notre cadre réduit en tant que $\sum_{i \in \{1, \dots, k_nouv\}} m(ef_i) = 1$, nous définissons un facteur de normalisation que nous notons $norm$. Nous proposons ainsi le passage des possibilités aux masses d'évidence décrit par l'équation (5.4) suivante. Ainsi, la masse d'un élément focal n'est autre que le quotient de sa possibilité par un facteur de normalisation qui assure que la somme des masses de tous les éléments focaux soit égale à 1.

$$m(ef_i) = \pi_x(ef_i) / norm \text{ avec } norm = \sum_{i=1}^{k_nouv} \pi_x(ef_i) \quad (5.4)$$

V.2.4 Calcul direct des fonctions de masse d'évidence

La deuxième méthode que nous proposons pour l'estimation des fonctions de masses d'évidence calcule les fonctions de masses directement à partir des fréquences extraites des histogrammes des niveaux de gris des zones d'apprentissages associées aux classes de l'ensemble de définition. Nous proposons de diviser chacune de ces fréquences par le pic de l'histogramme de fréquence correspondant. Ainsi pour chaque classe C_i et étant donné l'histogramme h_{C_i} calculé sur la zone d'apprentissage, nous déduisons la fonction f_{C_i} qui associe à chaque niveau de gris x , la valeur de sa fréquence $h_{C_i}(x)$ divisée par le pic de

l'histogramme h_{C_i} . Cette division nous garantit que les valeurs de f_{C_i} sont dans l'intervalle $[0,1]$.

En appliquant le même principe sur chaque histogramme h_{A_i} on obtient un nouvel histogramme f_{A_i} . Nous pouvons ainsi associer à chaque histogramme h_{ef_i} un histogramme f_{ef_i} suivant l'équation (5.5) suivante :

$$f_{ef_i}(x) = h_{ef_i}(x) / \max(h_{ef_i}) \quad (5.5)$$

Ainsi les masses de croyance de chacun des éléments focaux peut être calculé directement à partir de leurs histogrammes de niveaux de gris. Cette opération est décrite par l'équation (5.6) suivante :

$$m(ef_i) = f_{ef_i}(x) / S \text{ avec } norm = \sum_{i=1}^{k \text{ nouv}} f_{ef_i}(x) \quad (5.6)$$

norm est le facteur de normalisation.

V.3 Approche multifractale pour la caractérisation de la texture

Nous avons proposé des solutions pour le problème de l'explosion combinatoire dans la section précédente, cependant un autre problème d'ordre applicatif reste à résoudre : c'est l'incapacité de l'information radiométrique utilisée dans les méthodes classiques de classification à représenter la totalité de l'information contenue dans une image de télédétection et surtout pour le cas des images haute résolution comme celles qu'on traite dans notre application. Cette section introduit les notions d'outil multifractal via les exposants de singularité et ceci pour la caractérisation de la texture à travers le calcul des fonctions de masse « texturale » [Ben Dhiaf et al. 2008 a].

V.3.1 Notion de texture et méthodes de représentations

La multiplicité des textures entraîne une multiplication des définitions. Cependant, toutes s'accordent à séparer les textures en deux classes : les textures structurées (macrotextures) et les textures aléatoires (microtextures). Une texture qualifiée de structurée est constituée par la répétition d'une primitive à intervalles réguliers. Les textures qualifiées d'aléatoires se distinguent en général par un aspect plus fin (sable, laine tissée, herbe, ...). Contrairement aux textures de type structurée, les textures aléatoires ne comportent ni primitive isolable, ni fréquence de répétition. On ne peut donc pas extraire de ces textures une primitive qui se répète dans l'image, mais plutôt un vecteur de paramètres statistiques homogènes à chaque texture.

Les méthodes conventionnelles de classification d'images sont des protocoles uniquement fondés sur une discrimination d'ordre radiométrique. Pour leurs part, les méthodes

d'analyse texturale permettent de traiter plusieurs pixels simultanément, donc une information de type « contextuelle ». Les deux approches sont complémentaires.

Les textures rencontrées dans les images de télédétection étant généralement de type aléatoire, les méthodes basées sur une analyse statistique de l'image sont probablement les plus appropriées. Parmi ces dernières, les méthodes basées sur l'analyse des caractéristiques spatiales sont nombreuses et elles sont de loin les plus utilisées pour l'analyse des images de télédétection. Ces méthodes peuvent être groupées en quatre sous-groupes basées sur les paramètres suivants : les histogrammes généralisés de niveaux de gris, la mesure de l'activité du signal de texture, la morphologie mathématique et l'analyse fractale.

Dans l'approche fractale, l'amplitude des niveaux de gris peut être assimilée à l'altitude d'une surface géométrique. La dimension fractale de cette surface est utilisée pour caractériser la texture. En général, la dimension fractale est insuffisante pour la discrimination. Elle peut être complétée par un autre paramètre appelé lacunarité. Cette approche se révèle particulièrement fructueuse pour des textures aléatoires de type micro-texture, mais aussi macro-texture (échographie des poumons, par exemple).

Les méthodes multifractales sont dérivées de l'analyse fractale [Grazzini 2003]. Elles permettent de décrire la régularité locale et globale du signal. Dans le cadre de ce travail, nous utilisons les coefficients de singularités dans le but d'estimer de nouvelles mesures de masses d'évidence [Turiel et Parga 2000 a] [Turiel et Parga 2000 b].

V.3.2 Utilisation de l'outil multifractal

L'analyse multifractale des images consiste dans notre cas à définir une mesure à partir des niveaux de gris [Denoeux 2001], [Kennes 1992], [Lefevre et al. 2001] permettant de fournir une description à la fois locale et globale de l'image. Elle peut être réalisée à travers différentes approches : en analysant les propriétés statistiques des données, leurs propriétés géométriques ou les deux propriétés en même temps. Ces approches visent à vérifier une dépendance en loi de puissance d'une certaine variable suivant un paramètre d'échelle. Nous adoptons dans cette étude la dernière approche [Grazzini et al. 2006] [Grazzini et al. 2007].

Ceci revient à effectuer un test direct de la multifractalité en calculant les exposants de singularités en chaque point afin d'obtenir les composantes fractales et de vérifier que l'ensemble est organisé suivant une hiérarchie multifractale. Cette approche permet la localisation spatiale des structures de l'image suivant leurs propriétés fractales (on obtient un exposant pour chaque pixel de l'image). Nous décrivons dans ce qui suit cette approche pour estimer les coefficients de singularités [Abadi et Grandchamp 2006], [Bloch 2005], [Campos 2003], [Bloch 2003 b].

V.3.3 Construction de la mesure multifractale

Dans ce qui suit, nous allons travailler avec la norme du gradient de l'image ∇I plutôt que

sur l'image I elle-même, car il a été démontré que les images naturelles sont de nature non stationnaire contrairement à la norme du gradient des ces dernières.

Définition : Pour une image I représentée par sa fonction de luminance $I(\vec{x})$ en chaque pixel \vec{x} , on introduit une mesure de densité μ s'écrivant sous la forme (5.7) :

$$d\mu \equiv d\vec{x} |\nabla I|(\vec{x}) \quad (5.7)$$

Où $|\nabla I|(\vec{x})$ désigne la norme du gradient ∇I de l'image I en chaque pixel \vec{x} .

La mesure multifractale d'un sous ensemble quelconque A de l'image est donc donnée par l'équation (5.8) :

$$\mu(A) = \int_A d\vec{x} |\nabla I|(\vec{x}) \quad (5.8)$$

En pratique, le comportement local de l'intensité I en chaque pixel \vec{x} de l'image peut être caractérisé par l'évaluation de la mesure dans une boule $B_r(\vec{x})$ pour différents rayons r centré en un pixel \vec{x} tels que illustré comme suit par l'équation (5.9):

$$\mu(B_r(\vec{x})) = \int_{B_r(\vec{x})} d\vec{y} |\nabla I|(\vec{y}) \quad (5.9)$$

Cette mesure donne une idée de la variabilité locale des niveaux de gris autour du point \vec{x} .

Définition : une mesure est dite multifractale si la mesure $\mu(B_r(\vec{x}))$ de la boule $B_r(\vec{x})$ évolue comme une puissance de r à un exposant caractéristique $h(\vec{x})$, ne dépendant que de \vec{x} , lorsque r tend vers 0. Cette mesure s'écrit selon l'équation (5.10) suivante :

$$\mu(B_r(\vec{x})) = \alpha(\vec{x}) r^{d+h(\vec{x})} + o(r^{d+h(\vec{x})}) \quad (5.10)$$

Où d désigne la dimension de l'espace ($d=2$ pour des images) et où le coefficient $\alpha(\vec{x})$ ne dépend pas de l'échelle r .

V.3.4 Estimation des exposants de singularités

Les exposants de singularité apparaissant dans l'équation (5.10) permettent de caractériser la structure multifractale de l'image. Ils représentent le degré de singularité s'ils sont inférieurs à 0 ou de régularité de l'image s'ils sont supérieurs à 0. Pour mieux estimer ces exposants, on utilise une projection en ondelettes dont l'intérêt principal est de réaliser une interpolation continue de l'image. Ils permettent ainsi d'étudier l'évolution de la mesure sous l'effet de changement d'échelle dans le but de caractériser le comportement local de l'intensité de l'image I en chaque pixel \vec{x} . En effet, pour un choix d'ondelettes analysante appropriée, la

projection de la mesure multifractale exhibera également un comportement multifractal, dont la relation est décrite par l'équation (5.11):

$$T_{\psi}(\mu(\vec{x}, r)) = \alpha_{\psi}(\vec{x})r^{h(\vec{x})} + o(|r|^{h(\vec{x})}) \quad (5.11)$$

Les exposants de singularités $h(\vec{x})$ peuvent être estimés à partir des projections en ondelettes T à l'aide de log-log régression sur l'équation précédente. Ce qui donne l'équation (5.12) suivante :

$$h(\vec{x}) = \lim_{r \rightarrow 0} \frac{\log(T_{\psi}(\mu(\vec{x}, r)))}{\log(r)} \quad (5.12)$$

V.3.5 Estimation des fonctions de masses à partir des histogrammes des exposants de singularité

Étant donné qu'on se situe dans le cadre d'un système de classification supervisée, les distributions des coefficients de Hölder associées à chacune des zones d'apprentissages et correspondant aux classes de l'ensemble de définition peuvent être représentées par leurs histogrammes de singularités.

Pour simplifier l'exploitation de l'image des exposants de singularités et permettre son adaptation à la méthode d'estimation des fonctions de masse proposée dans la section V.2 précédente, on multiplie l'image des exposants de singularités par un facteur permettant d'avoir les mêmes bornes que l'image des niveaux de gris. La détermination de l'ensemble de discernement dépendra par conséquent de la distribution des coefficients de Hölder et donc des histogrammes tracés à partir des singularités de l'image. Nous obtenons des fonctions de masse à chaque élément du cadre de discernement affiné.

Les figures VI.3(a) et VI.8 (a) du chapitre VI donnent deux exemples d'images de Hölder issus de notre image moyenne résolution et d'une fenêtre de notre image haute résolution respectivement. Ces figures montrent aussi les histogrammes des exposants de singularités obtenus à partir des zones d'apprentissages choisies sur ces images. Une interprétation étendue de ces figures est présentée dans la section VI.2 du chapitre VI.

V.4 Estimation des fonctions de masse à partir de l'information contextuelle forestière

V.4.1 Introduction

Les sources autres que celles qui découlent d'une mesure spécifique d'un capteur de télédétection fournissent des données qui peuvent être utilisées par des règles expertes afin d'estimer des masses d'évidence qui enrichissent le système de fusion. C'est ainsi que le

modèle numérique du terrain peut être utilisé pour définir à travers des règles une estimation de masse qui est corrélée avec l'altitude. En effet, souvent dans la nature, quelques espèces forestières n'apparaissent qu'à un niveau donné d'altitude, d'où l'importance de répartir dans ce cas la masse d'évidence sur les combinaisons possibles au regard de la connaissance décrite par l'expert.

De même, les inventaires antérieurs que l'on dispose sur la scène étudiée sont utilisés comme une connaissance temporelle qui informe sur les éventuelles évolutions et qui permettent de restreindre les événements composés à des singletons ou des combinaisons de classes possibles.

Aussi, l'image haute résolution permet de délimiter les couronnes d'arbre puisqu'un arbre apparaît comme un ensemble de pixels identifiables. Ces couronnes délimitées à travers des algorithmes de délimitations de couronnes (cf V.4.2) offrent un moyen de définir à travers les règles expertes des masses d'évidence qui incluent des singletons et des combinaisons inappropriés. Toutefois les règles experts peuvent être fondées sur un ou plusieurs attributs émanant de sources diverses. L'une des formes d'estimation est formulée de la façon suivante :

$$\text{Si } (h_1, h_2, \dots, h_k) \text{ alors } \{A_1, A_2, \dots, A_l\}$$

h_i ($i \in [1, \dots, k]$) étant une hypothèse faisant intervenir des attributs dégagés à partir d'une source S et A_j ($j \in [1, \dots, l]$), les évènements correspondants.

Exemple :

Si le niveau du MNT est supérieur à 2000 mètres et que le point à classer se situe à l'intérieur d'une couronne d'arbre alors l'événement composée $C_1 \cup C_2$ est soutenu avec une confiance α (une constante comprise entre 0 et 1).

V.4.2 Algorithmes de détection des couronnes d'arbres

Dans cette section, nous nous intéressons particulièrement à la classification des images forestières à l'arbre près. Afin d'extraire les couronnes d'arbres nécessaire à la classification, nous introduisons tout d'abord quelques algorithmes d'extraction de couronnes d'arbres. Ces algorithmes se réfèrent à quatre approches : Approche contour, approche région, approche objet et approche basée sur la morphologie mathématique.

Les algorithmes d'extractions des couronnes, associées à ces approches sont respectivement l'algorithme suivi de vallées [Gougeon 1995] pour l'approche contour, l'algorithme de croissance de régions par mouvement brownien [Erickson 2004 b] pour l'approche région, l'algorithme du processus ponctuel marquée [Perrin 2006] pour l'approche objet et l'algorithme de la ligne de partage des eaux [Beucher et Lantuéjoul 1979] pour l'approche de morphologie mathématique.

A la fin de cette sous-section nous essayons d'évaluer ces algorithmes et de comparer quelques résultats.

V.4.2.1 *Approche contour : Algorithme de suivi des vallées*

L'un des algorithmes d'extraction de couronnes d'arbres est le suivi des vallées ("valley-following") [Gougeon 1995]. Cet algorithme utilise les bandes d'ombre autour des arbres qui sont révélatrices de leur présence. Son hypothèse de départ c'est le fait que les couronnes des arbres sont perçues distinctement sur les images à haute résolution parce qu'elles constituent des entités brillantes séparées par des zones d'ombre.

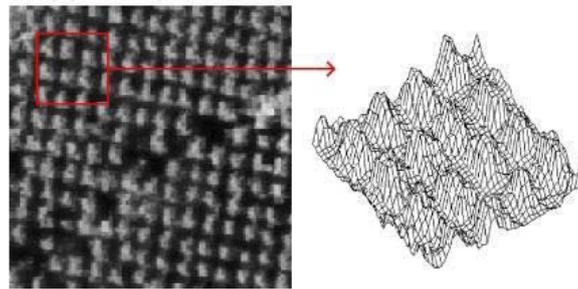


Figure V.1. Extrait d'une carte topographique 3D d'une portion de forêt.

Le fonctionnement de cet algorithme est le suivant, un procédé de « suivi des vallées » parcourt de multiples chemins entre les arbres pour essayer de suivre les zones d'ombre qui se profilent généralement entre les houppiers des peuplements forestiers denses, de la même manière qu'on suivrait des vallées entre des montagnes comme représentée dans la figure V.1. Cela donne une assez bonne séparation des cimes des arbres, bien que souvent incomplète. L'algorithme applique un procédé à base de règles et examine individuellement les arbres potentiels. Il suit la limite de la couronne dans le sens des aiguilles d'une montre en cherchant à délimiter des zones fermées. Enfin, des règles d'ordre supérieur permettent de prendre des décisions concernant l'utilisation d'outils additionnels pour séparer ou regrouper d'avantage ces zones fermées.

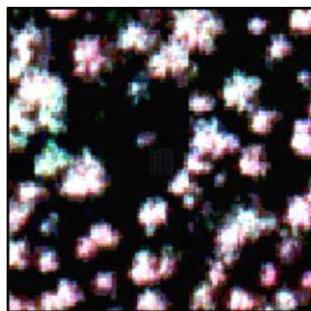
Le bon déroulement de cet algorithme repose sur trois seuils qui varient en fonction de la qualité des images et des couronnes des arbres elles mêmes. Ces trois seuils interviennent dans les différentes étapes du processus d'extraction des couronnes.

Le premier seuil, généralement appelé seuil inférieur, permet d'éliminer du traitement les étendues dépourvues d'arbres importants et celles qui se trouvent essentiellement à l'ombre. Il est utilisé comme simple seuil sur toute l'image et permet de masquer tout pixel présentant un niveau de gris inférieur à sa valeur. Ceci accélère le traitement et empêche l'algorithme de créer des vallées inutiles et vides de sens à l'intérieur de ces étendues. Une valeur trop élevée de ce seuil peut entraîner une mauvaise délimitation des couronnes ainsi que des mesures

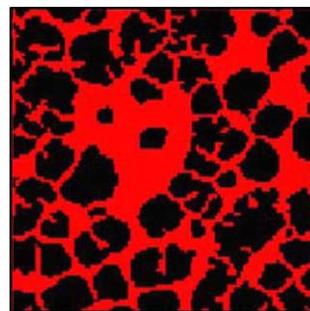
inappropriées de leur surface. Une valeur trop faible entraînera une mauvaise séparation des couronnes à l'intérieur des groupes d'arbres.

Le deuxième seuil, généralement appelé le seuil supérieur, a comme fonction d'aider à distinguer les vallées utiles à la séparation des cimes d'arbres de celles qu'on trouve généralement à de plus grandes résolutions spatiales (10-40 cm/pixel) et qui ont tendance à séparer les couronnes en plusieurs parties, particulièrement dans le cas d'espèces présentant des couronnes en forme d'étoile.

Le troisième seuil, généralement appelé seuil de rugosité des vallées, est une mesure de la quantité d'instabilité radiométrique à laquelle on devrait s'attendre et qu'on peut tolérer dans les vallées [Gougeon et Leckie 2003]. Le résultat de l'exécution de l'algorithme de suivi de vallées (SV) est présenté dans la figure V.2 suivante.



(a) : image initiale de taille 100*100



(b) : Résultat après exécution de l'algorithme suivi des vallées

Figure V.2. Extrait d'une carte topographique 3D d'une portion de forêt.

V.4.2.2 Approche région : Algorithme croissance de régions par mouvement brownien

Cette approche a été proposée dans [Erickson 2004 b] et consiste en une croissance de régions par mouvement brownien (CRMB) « region growing by brownion motion », l'algorithme est divisé en deux parties :

La première consiste à détecter les maximums locaux, qui correspondent aux sommets des couronnes d'arbres. Un seuillage est appliqué pour ne garder que les arbres et une matrice de distance D est créée pour mesurer la distance de chaque point de l'image par rapport à l'arrière plan. Le lissage de cette image par un filtre gaussien sera l'étape suivante. Enfin l'extraction des maxima locaux se fait en appliquant un masque sur l'image lissée.

La deuxième partie est l'extraction des couronnes d'arbre, elle débute par la création de l'image Numpass avec la taille de l'image initiale. Cette image va être créée en partant de tous les maximums locaux extraits dans la première partie de l'algorithme, et pour chaque maximum local on simule le phénomène de mouvement brownien qui représente le mouvement aléatoire d'une particule en suspension dans un fluide [Erickson 2004 a], [Erickson 2004 b], il s'agit en effet de sommer des vecteurs aléatoires 2D, la somme des n vecteurs aléatoires est la position de

la particule après n étapes.

Pour s'assurer que la particule ne dépasse pas les limites des régions et atterit dans le background, avant d'ajouter le vecteur à la somme, on vérifie si le fait de l'ajouter ne propulsera pas la particule vers un pixel noir donc de niveau de gris égal à 0. L'image Numpass présentera alors le nombre de passages de la particule pour chaque pixel.

L'étape suivante est la création de régions et donc l'obtention de l'image segmentée en essayant d'extraire les frontières entre les couronnes qui chevauchent, cette étape permet d'affecter chaque pixel à la région à laquelle il appartient tout en extrayant les frontières entre ces dernières. Les figures V.12(d) (et V.12 (e)) illustrent le résultat de l'application de cet algorithme avec un masque 11×11 et un seuil 0.5.

La figure V.3 suivante illustre le fonctionnement de l'algorithme de croissance de régions par mouvement Brownien.

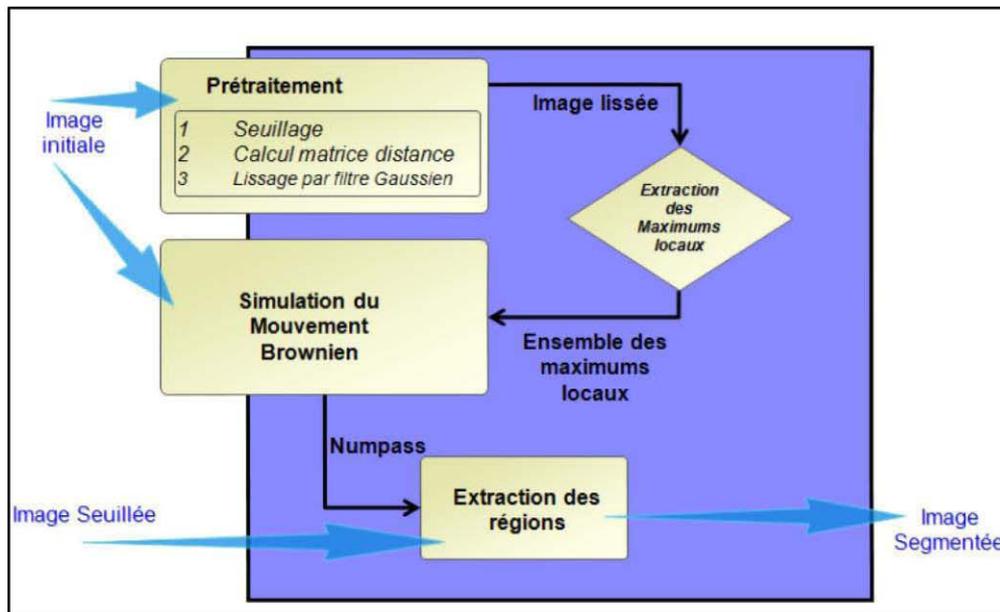


Figure V.3. Diagramme des étapes de l'algorithme de Croissance de Régions par Mouvement Brownien.

Le bon fonctionnement de cette approche dépend des trois paramètres essentiels, le premier paramètre est le seuil inférieur, il a le même rôle que celui présenté dans l'algorithme du suivi des vallées, le deuxième paramètre est la taille de la fenêtre qui permet l'extraction des maximums locaux, cette fenêtre dépend de la taille des arbres. Une mauvaise estimation de la taille de la fenêtre peut générer un excès ou une sous estimation des maximums locaux. Le troisième paramètre est le nombre de pas utilisés dans le mouvement brownien, une sous-estimation ou une surestimation de ce dernier peut engendrer une anomalie au niveau de la taille de la couronne ou de sa forme.

Le choix de ces paramètres est guidé par la nature des images, leurs résolutions, les

espèces dominantes dans la scène, leurs réflectances ainsi que l'étendue de leurs couronnes. Une phase d'apprentissage et de simulation est souvent nécessaire pour fixer ces paramètres.

L'annexe C illustre le paramétrage de cet algorithme avec l'application sur des fenêtres de notre image Quickbird.

V.4.2.3 Approche Objet : Processus ponctuel marqué

L'approche objet est une approche qui se base sur le calcul de patrons. La forme que l'on cherche est la réalisation d'un processus ponctuel marqué. Un processus ponctuel marqué est représenté par un ensemble aléatoire $\gamma = \{y_n = (k_n, m_n)\}$ tels que $n \in \mathbb{N}_0$ avec :

- Points k_n : emplacement des objets
- Marques m_n : caractéristiques des objets (forme géométrique d'un objet aléatoire, mais aussi : espèce, âge, maladie, ect.)

Pour le cas de délimitation d'arbres basé sur les processus ponctuels marqués, il s'agit de rechercher la meilleure configuration d'objets (en l'occurrence des ellipses) pour décrire l'arrangement de ces arbres dans les images. Les patrons sont des rendus mathématiques de l'apparence des arbres de différents formats, géométries et points de vue. L'extraction des couronnes d'arbres se fait en essayant de chercher l'occurrence des patrons dans l'image.

Larsen et Rudemer [Larsen et Rudemo 1997] utilisent des patrons elliptiques qui dérivent d'un modèle correspondant aux couronnes d'arbres (voir figure V.4). La forme des arbres est modélisée par un ellipsoïde généralisée illustrée par l'équation 5.13 où z est l'axe vertical, a la demi hauteur de la couronne, b sa demi largeur et $n \geq 1$ un paramètre de forme.

$$\left((x^2 + y^2)^{n/2} \right) / b^n + \left((z^2)^{n/2} \right) / a^n = 1 \quad (5.13)$$

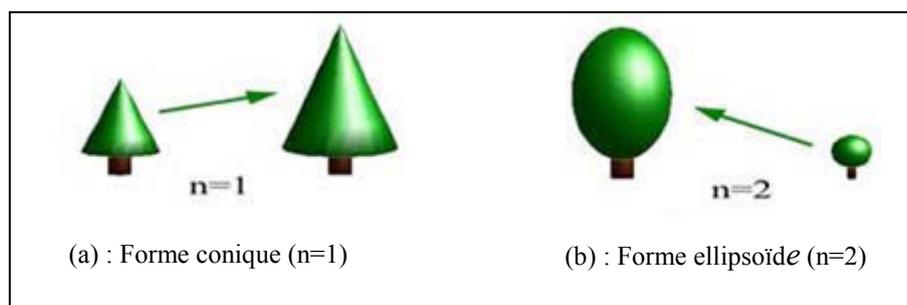


Figure V.4. Différentes formes de patrons.

Un modèle de réflexion / absorption de la lumière par le feuillage de l'arbre et par le sol est constituée pour obtenir le patron. Ce modèle nécessite la donnée de la position du soleil et de la caméra, ainsi que la hauteur et la taille approximative des couronnes pour calculer le patron. La recherche des maximums locaux de la fonction de corrélation des transposées de ce patron dans l'image conduit à trouver un certain nombre de positions des arbres. Il est à noter que des méthodes de post-traitement, lorsque l'on connaît certains paramètres comme le nombre

d'arbres a priori, permettent d'affiner le résultat. Par exemple, cette valeur peut être estimée à l'aide d'une recherche de maxima locaux sur l'image lissée par convolution avec une gaussienne pour les arbres situés près du point Nadir (voir figure V.5) [Perrin 2006].

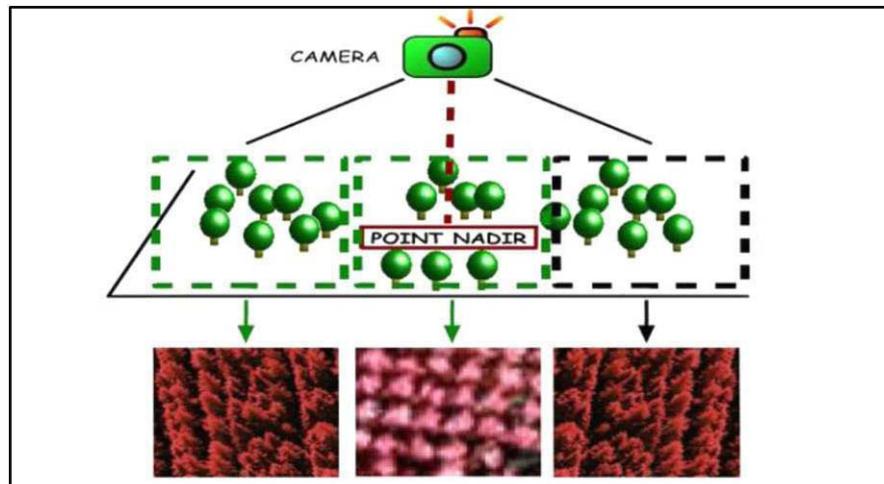


Figure V.5. *Prise de vue des photographies aériennes et point Nadir : projeté orthogonal sur le sol de la caméra.*

Perrin et al. [Perrin et al. 2005] modélisent les peuplements forestiers par un processus ponctuel marqué en se basant, pour séparer les arbres, sur les ombres des arbres elles mêmes, orientées dans une direction privilégiée ou des ombres de leurs voisins, ce qui crée une zone sombre. Les auteurs cherchent ainsi à extraire des images des objets x dont la distribution interne des niveaux de gris diffère de celle de leur environnement proche $f(x)$ est la fonction représentative de la frontière. Pour quantifier la différence entre les niveaux de gris à l'intérieur et à l'extérieur de la couronne (du patron), Perrin et al. utilisent la distance de Bhattacharya. Cette distance représente la différence entre les distributions de niveaux de gris des pixels de deux ensembles. Pour cela, les auteurs suppose que ces distributions sont des gaussiennes, dont les paramètres sont calculés à l'aide d'estimateurs classiques.

Une fonction de qualité $Q_a(d)$ est alors calculée pour une distance donnée $d \in \mathbb{R}^+$. L'énergie d'attache aux données U_d d'un objet x est égale à la fonction de qualité définie au niveau de l'équation (5.14). Ainsi, il est essentiel de faire en sorte que les objets qui répondent bien aux données, avec une forte valeur de $d_B(x, f(x))$, aient un potentiel négatif pour être attractifs. Le principal paramètre à fixer est donc la distance d_0 au delà de laquelle un objet aura une énergie d'attache négative. Seuls des objets avec une distance de Bhattacharya au dessus de ce seuil seront acceptés à très basse température. Les autres paramètres de la fonction de qualité $Q_a(d)$ sont des paramètres de seuil, afin que $Q_a(d) \in [V_m, V_M]$.

Les résultats de l'extraction de couronnes d'arbres obtenues par Perrin sont représentés dans la figure V.6 [Perrin 2006].

$$U_d(x) = Q_a(d_B(x, f(x))) \quad \text{Avec :} \quad Q_a(d) = \begin{cases} V_M \left[1 - \frac{d}{d_0} \right] & \text{si } d < d_0 \\ V_m \left[1 - \exp\left(\frac{-(d - d_0)V_M}{d_0|V_m|}\right) \right] & \text{sinon} \end{cases} \quad (5.14)$$

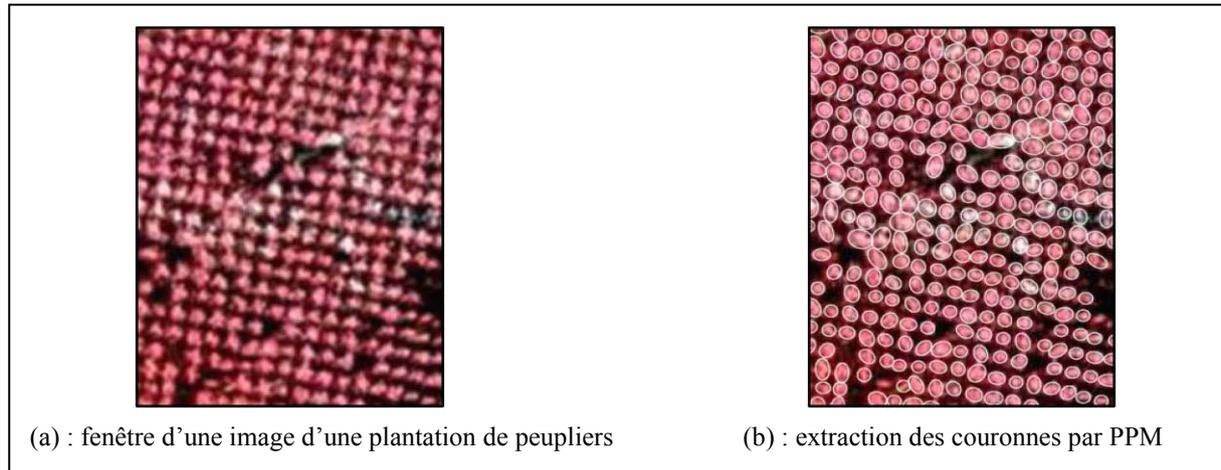


Figure V.6. Résultat de l'extraction des couronnes selon G.Perrin [Perrin 2006] sur une fenêtre d'une image d'une plantation de peupliers.

V.4.2.4 Approche par Morphologie mathématique : Ligne de partage des eaux

La morphologie mathématique [Serra 1982] est une théorie largement employée en traitement d'images binaires et numériques. Elle propose des transformations non linéaires utilisées en filtrage et amélioration d'images, segmentation, mesures, reconnaissance des formes. Puisqu'elle repose essentiellement sur des concepts ensemblistes et des propriétés algébriques, la morphologie mathématique apparaît comme une suite logique dans la série des opérations manipulant l'information spatiale et de leur extension au flou. Un autre intérêt de l'extension de la morphologie mathématique (MM) au flou est que d'autres opérateurs peuvent en être déduits (adjacence ou distance par exemple).

Les quatre opérations de base de la morphologie mathématique sont l'érosion, la dilation, l'ouverture et la fermeture, à partir desquelles de nombreuses autres opérations peuvent être construites. Ces opérations sont appliquées à une image I par un élément structurant B comme le montrent les équations (5.15) jusqu'à (5.19) suivantes.

L'érosion d'une image I par un élément structurant B est définie en un point par l'équation (5.15) suivante:

$$E_B(I)(x, y) = \min \{ I(x + i, y + j) \mid (i, j) \in B \} \quad (5.15)$$

La dilatation d'une image I par un élément structurant B est définie en un point par

l'équation (5.16) suivante :

$$D_B(I)(x, y) = \max \{I(x-i, y-j) | (i, j) \in B\} \quad (5.16)$$

L'ouverture de l'image I par l'élément structurant B est définie par une érosion suivie d'une dilatation comme illustré par l'équation (5.17) :

$$O_B(I) = D_B(E_B(I)) \quad (5.17)$$

La fermeture de l'image I par l'élément structurant B est définie par une dilatation suivie d'une érosion comme illustré par l'équation (5.18) :

$$F_B(I) = E_B(D_B(I)) \quad (5.18)$$

Le gradient morphologique est défini par par l'équation (5.19) suivante:

$$Grad_morph(I) = D_B(I) - (E_B(I)) \quad (5.19)$$

où B est l'élément structurant boule unitaire (boule de rayon 1).

La ligne de partage des eaux (LPE) constitue l'approche morphologique de la segmentation d'une image en niveaux de gris. Le but est d'obtenir une partition de l'image en régions regroupant des pixels jugés équivalents en fonction d'un certain critère. Cette technique tire son nom d'une analogie avec la géophysique. En effet, les valeurs d'intensité des pixels d'une image sont considérées comme une information d'altitude (représentation surfacique sous forme de paysage «montagneux»). Dans ce cas, l'image est représentée comme un terrain en trois dimensions (*carte d'élévation*) comme illustrée dans la figure V.7. Le principe est alors de remplir progressivement d'eau chaque bassin du terrain. Chaque bassin représente une région.

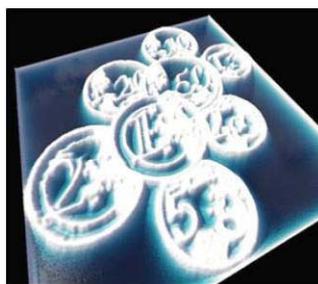
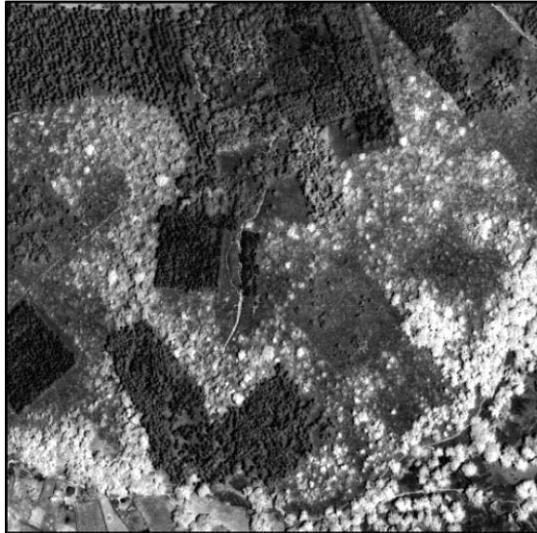


Figure V.7. Représentation d'une image sous forme de terrain 3D et remplissage des bassins avec de l'eau.

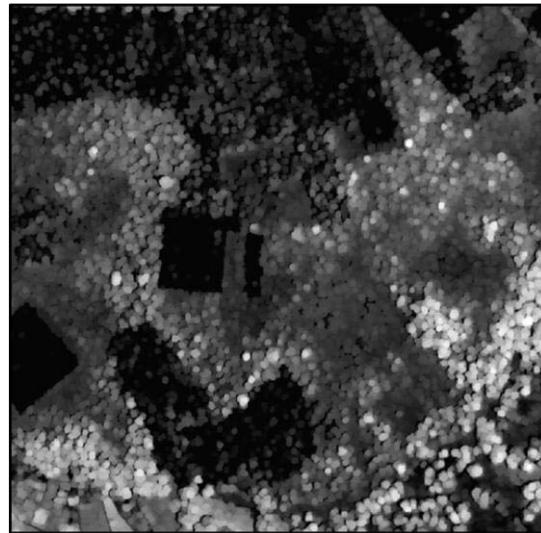
La carte d'élévation est une image dont les valeurs représentent une altitude. Pour construire cette image nous partons du gradient de l'image. Dans la carte d'élévation, l'altitude la plus élevée est assignée aux pixels ayant un fort gradient ainsi qu'aux bords de l'image. Cela donne les lignes de crête. La valeur d'altitude des autres pixels est calculée en fonction de l'éloignement de la ligne de crête : plus nous nous éloignons de la ligne de crête, plus l'altitude

doit décroître. Les bassins versants de l'image du gradient sont les régions homogènes de l'image originale. La LPE effectue une segmentation par partitionnement en bassins versants de la surface des niveaux de gris. On cherche les bassins versants pour partitionner ce paysage.

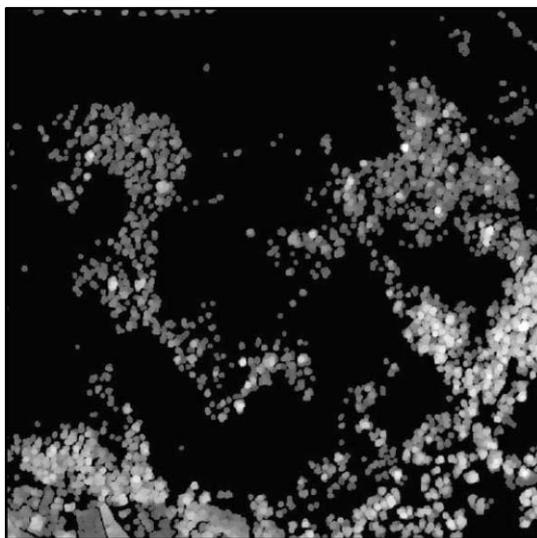
La LPE présente l'avantage de partitionner de manière complète l'image et de donner des contours fermés. Cependant son inconvénient consiste en une sur-segmentation systématique. Cette sur-segmentation doit être résolue par des post-traitements.



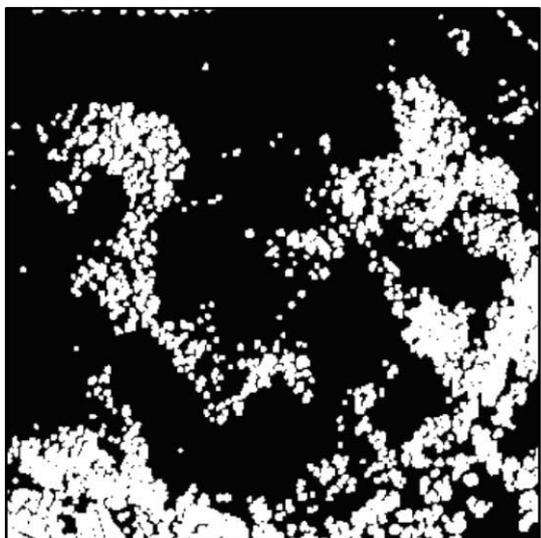
(a) : fenêtrage 1000*1000 de notre image QuickBird



(b) : ouverture appliquée suite à LPE



(c) : Seuillage de (b)



(d) : image binaire associée à (c)

Figure V.8. Détermination des couronnes d'arbres par opérateurs LPE et ouverture de la MM.

La figure V. 8 présente un exemple d'application de morphologie mathématique sur une fenêtre PIR de notre image Quickbird. Les étapes que nous avons suivies pour obtenir ce résultat consistent tout d'abord à appliquer un filtrage 2D (sobel) de l'image suivi d'un filtrage ND et la détermination du gradient magnitude de l'image. Ensuite nous avons appliqué l'algorithme LPE sur cette image gradient. L'élément morphologique structurant que nous avons choisi est un disque (de rayon 5). Nous avons procédé ensuite à une ouverture morphologique de l'image obtenu après watershed. Cette ouverture permettra d'éliminer les

petites composantes (de taille inférieure de celle de l'élément structurant) et de lisser les formes.

V.4.2.5 *Evaluation des algorithmes de détection des couronnes d'arbres*

Nous avons présenté quatre approches différentes pour l'extraction des couronnes d'arbres, la première remarque que nous pouvons faire est qu'aucune approche n'est parfaite et qu'aucune d'entre elles ne peut s'adapter à toutes les images et à tous les types de forêts.

L'algorithme de suivi des vallées est pratique pour les formes coniques d'arbres qui créent naturellement des zones d'ombre entre les tiges. Par contre, un problème surgit pour les gros arbres vu que l'algorithme a tendance à les casser. Un autre inconvénient rencontré consiste dans la provocation de fausses alarmes dans les zones ouvertes et donc une détection excessive et exagérée de couronnes peut avoir lieu. Finalement, le choix des seuils (inférieur, supérieur et de rugosité comme détaillée dans le paragraphe V.4.2.1) est primordial pour le bon fonctionnement de la méthode, un mauvais choix peut entraîner une détérioration de la forme des arbres.

L'algorithme de croissance de régions par mouvement brownien présente un premier inconvénient qui est sa dépendance de différents paramètres tels que le seuil, la taille de la fenêtre pour l'extraction des maximums locaux et enfin le nombre de pas pour la simulation du mouvement Brownien. L'hypothèse de départ de cet algorithme qui stipule que les maximums locaux représentent les sommets des couronnes n'est pas toujours vraie, chose qui peut détériorer les performances de l'algorithme.

Dans [Elouadi et Ben Dhiab 2009], nous avons proposé une approche multi-agents de coopération (MA) entre les méthodes croissance des régions et suivi de vallées. Nous avons alors conçu des agents Regions et des agents Contours distribués sur la totalité de l'image et opérant d'une manière autonome et guidée par les connaissances. Cette approche MA donne des résultats plus corrects que les deux méthodes ECMB et SV (figure V.9), notamment sur des images éparées, elle réduit les erreurs de commission et d'omission grâce aux mécanismes de fusion et de division décidé par les agents selon les résultats locaux et intermédiaires obtenus et dégage des limites plus précises entre les couronnes d'arbres grâce à la coopération.

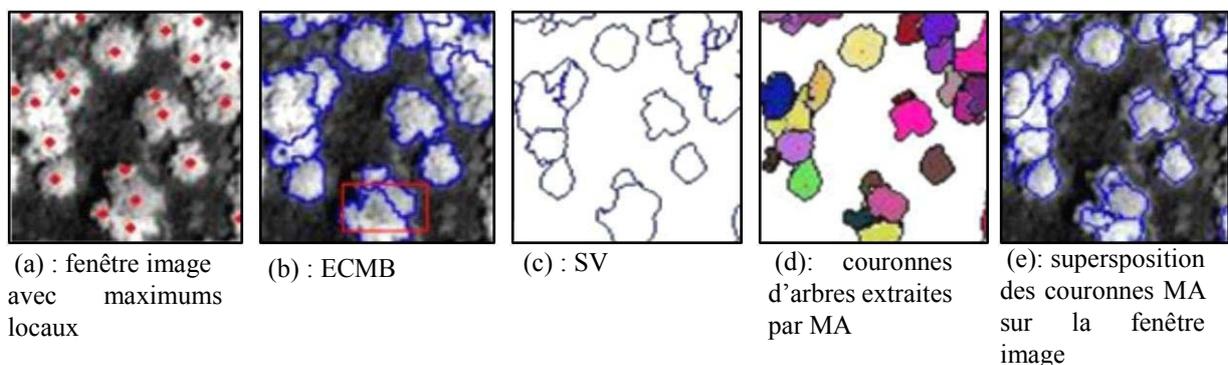


Figure V.9. *Extraction des couronnes par ECMB, SV, MA.*

Pour l'approche objet, le principal inconvénient est le fait que le calcul des patrons nécessite plusieurs données qui ne sont pas toujours disponibles. L'indisponibilité d'une de ces données peut provoquer une perte des formes des patrons et donc une mauvaise reconnaissance des régions.

Une comparaison entre les algorithmes PPM et CR est apparue dans [Perrin 2006] comme le montre la figure V.10 et dans [Ericksson 2004 b] comme illustré dans la figure V.11. Pour l'image de plantation de la figure V.10, les deux algorithmes ne rencontrent pas de problème de détection à l'intérieur de la plantation et nous ne remarquons pas une différence entre les résultats obtenus. La différence majeure entre eux se focalise dans leurs façons d'appréhender les zones de non végétations. Pour l'image de futaie dense de la figure V.11, l'algorithme de croissance de régions (CR) présente le meilleur résultat alors que l'algorithme PPM a tendance à sous estimer le nombre d'arbres.

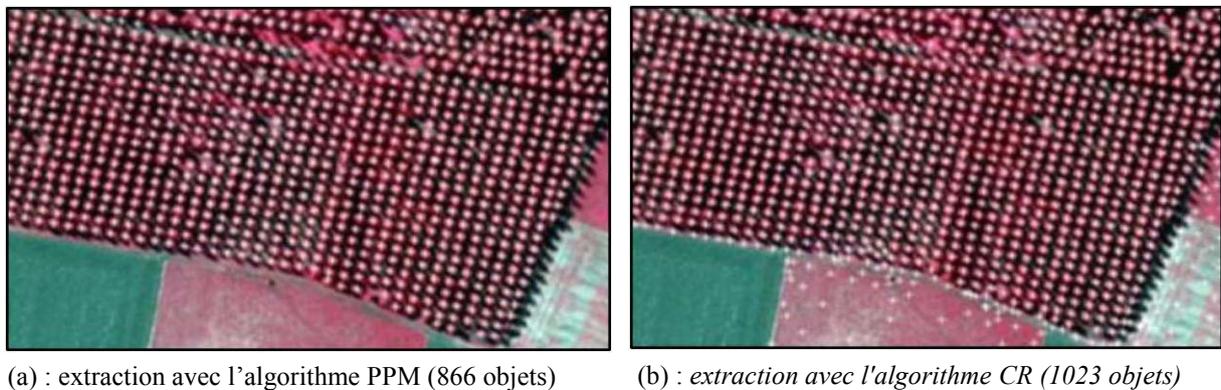


Figure V.10. Extraction des arbres sur une fenêtre d'une image aérienne infrarouge colorée d'une zone éparse avec les algorithmes PPM et CR

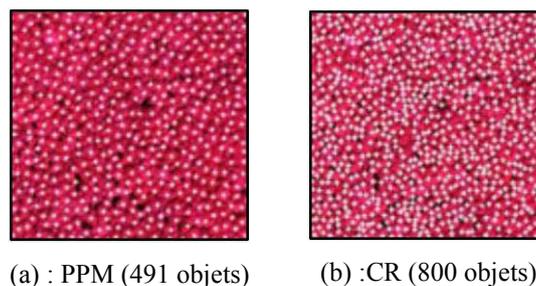
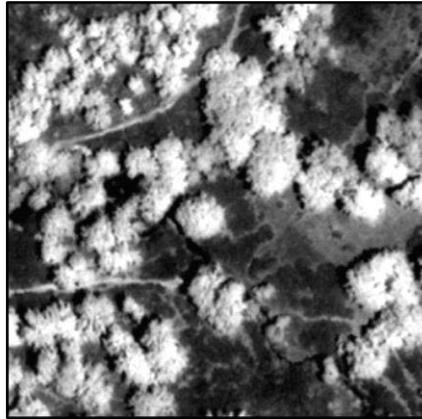


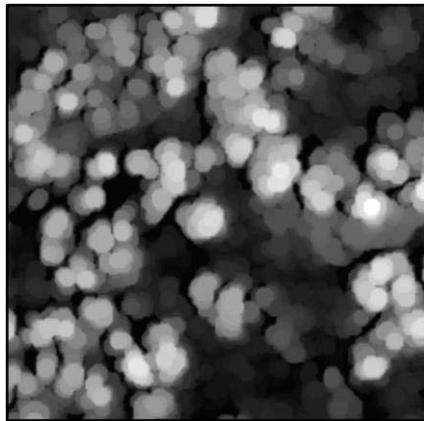
Figure V.11. Extraction des arbres sur une fenêtre d'une image aérienne infrarouge colorée d'une zone dense avec les algorithmes PPM et CR.

La figure V.12 montre une fenêtre de notre image Quickbird de taille 250*250. Nous avons appliqué sur cette fenêtre les mêmes étapes décrites pour l'application de la figure V.8 (filtrage, gradient magnitude, LPE, ouverture). Nous remarquons que les deux résultats sont assez satisfaisants. Cependant l'ECMB permet de préserver la forme des couronnes et permet de détecter des couronnes de taille différentes sur la même fenêtre. Il n'en est pas de même pour le résultat que nous avons obtenu par Morphologie Mathématique (LPE + ouverture) qui donne

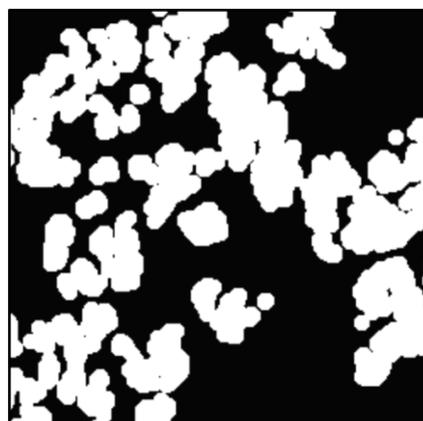
des couronnes de même forme et taille, mais il est plus rapide que l'algorithme ECMB.



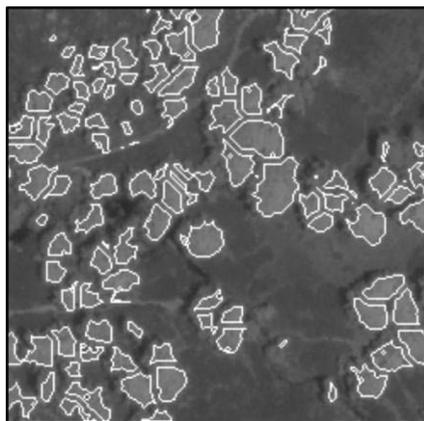
(a) : fenêtre 250*250 de notre image QuickBird



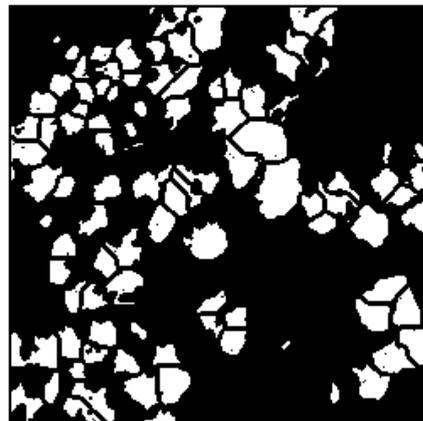
(b) : ouverture appliquée suite à LPE



(c) : image binaire apres seuillage de l'image (b)



(d) : couronnes extraites par ECMB superposées sur l'image



(e) : image binaire obtenue par ECMB

Figure V.12. Extraction des arbres sur une fenêtre d'une image aérienne infrarouge colorée d'une zone dense avec les algorithmes PPM et CR.

V.4.3 Intégration de l'information contextuelle pour le transfert des croyances dans un système de fusion de sources d'informations – Application à la détection et la classification des couronnes

La partie dynamique du Modèle des Croyances Transférables concerne la révision des croyances suite à la prise de connaissance de nouvelles informations [Pollock 2000].

Le transfert de croyance dans le MCT satisfait la règle de conditionnement de Dempster. Ainsi, la fonction de masse qui en résulte est celle obtenue par l'application de la règle de conditionnement non normalisée. Smets considère que les sources à combiner sont fiables et recommande alors de ne pas distribuer la masse du conflit sur toute les propositions mais juste sur l'ensemble vide. La combinaison proposée est donnée par l'équation (5.20):

$$\begin{cases} m(A) = \sum_{B \cap C = A} m^{S_1}(B) \times m^{S_2}(C), \quad \forall A \subset 2^\Omega \\ m(\phi) = \sum_{B \cap C = \phi} m^{S_1}(B) \times m^{S_2}(C) = K \end{cases} \quad (5.20)$$

La masse conditionnelle qui résulte est notée $m[B](\cdot)$ (les crochets traduisent le conditionnement) et ces éléments sont donnés par la règle de conditionnement de Dempster non normalisé selon les équations (5.21) :

$$m[B](A) = \begin{cases} \frac{1}{1 - \sum_{C \subseteq \bar{B}} m(C)} \sum_{C \subseteq B} m(A \cup C) & \text{si } A \subseteq B \text{ et } A \neq \phi \\ 0 & \text{si } A \not\subseteq B \text{ ou } A = \phi \end{cases} \quad \text{et } m(\phi|B) = 0 \quad (5.21)$$

Ainsi, $m[B](A) = 0$ si B n'est pas inclus dans A et $mB = 1$.

V.4.3.1 Intégration de l'information contextuelle

Dans IV.5.2 nous avons proposé un moyen de gestion du conflit par détermination d'un sous ensemble de sources pour chaque contexte. Cette approche réduit la complexité car c'est une question pour chaque contexte d'écarter certaines sources et de considérer seulement un sous ensemble de ces sources validé par des variables contextuelles.

Dans ce paragraphe nous proposons une autre méthode, profitant du contexte, et consistant à réduire l'ensemble des classes possibles pour un contexte bien défini [Ben Dhiaf 2009] [Ben Dhiaf et al. 2010].

Soit $Z = \{z_1, z_2, \dots, z_p\}$, l'espace de tous les contextes possibles, composé de p contextes z_j avec $j \in \{1, \dots, p\}$. D'où l'ensemble des variables contextuelles peut être écrit dans la forme suivante illustrée par l'équation (5.22). Chaque ligne de la matrice $M_{\text{contextes}}$ correspond à une variable contextuelle.

Soit $Contexte = [\alpha_1, \alpha_2, \dots, \alpha_k]$, ($\alpha_i \in \{0,1\}$) un vecteur décrivant le contexte. La taille de ce vecteur correspond au nombre de classes.

$\alpha_i = 1$, si C_i est possible dans le contexte considéré, sinon $\alpha_i = 0$ (C_i appartient à l'ensemble des classes impossibles: $C_i \in \overline{Contexte}$).

$$M_{\text{contextes}} = \begin{bmatrix} \alpha_{11}, \alpha_{12}, \dots, \alpha_{1k} \\ \alpha_{21}, \alpha_{22}, \dots, \alpha_{2k} \\ \vdots \\ \alpha_{p1}, \alpha_{p2}, \dots, \alpha_{pk} \end{bmatrix} \quad (5.22)$$

Nous pouvons considérer quelques exemples de variables contextuelles : Altitude, Couronne et Structure :

Le contexte Altitude peut prendre les valeurs : haut, moyen, faible

Le contexte Couronne peut prendre les valeurs : intérieur couronne, extérieur couronne

La structure peut prendre les valeurs : circulaire, rectangulaire, ellipsoïdale.

Dans notre application, nous considérons les contextes : *Couronne* (intérieure d'une couronne) et $\overline{Couronne}$ (extérieure d'une couronne).

A l'intérieur de la couronne d'un arbre par exemple, les classes qui représentent des espèces non forestières sont à écarter (classes impossibles). Ainsi l'idée est de transférer la masse associée aux classes impossibles vers les classes possibles.

Nous proposons un transfert des croyances selon le contexte couronne. Nous allons appeler les masses obtenues après ce transfert basé sur l'information contextuelle des *masses contextuelles*.

V.4.3.2 Intégration de l'information structurelle

Dans ce paragraphe, nous nous intéressons à l'information structurelle issue de la couronne d'un arbre. Les indices de formes qui peuvent être utilisés sont variés : surface, périmètre, circularité, rectangularité, ellipsité. Nous retenons pour cette application l'aire des couronnes comme caractéristique (ou attribut) structurelle.

Nous écrivons la distribution des masses contextuelles selon la forme suivante (5.23) :

$$m(C_i) = x_i, \quad x_i \neq 0 \text{ Si } C_i \in \text{couronne (contexte)}$$

$$\text{et } x_i = 0 \text{ Si } C_i \in \overline{\text{couronne (contexte)}} \quad (5.23)$$

La distribution de masses que nous proposons pour la source structurelle est basée sur un calcul

de distances. Ainsi, nous écrivons la masse d'une couronne selon l'équation (5.24) :

$$m_{\text{couronne}}(C_i) = \frac{1 - d_i}{D} \quad (5.24)$$

$$\text{avec : } d_i = \frac{|a - a_i|}{\text{norm}} \quad \text{avec } \text{norm} = \max_{i \in \{1, \dots, k\}}(a_i) - \min_{i \in \{1, \dots, k\}}(a_i)$$

$$D = \sum_{i \in \{1, \dots, k\}}(d_i)$$

a : Surface de la couronne considérée

a_i : Surface moyenne des couronnes de la $i^{\text{ème}}$ classe (C_i)

$\max_{i \in \{1, \dots, k\}}(a_i)$: Maximum de la surface moyenne de toutes les classes

et $\min_{i \in \{1, \dots, k\}}(a_i)$: Minimum de la surface moyenne de toutes les classes

Il s'agit ensuite de combiner la masse structurelle avec l'ensemble des masses issues des autres sources à considérer dans le processus de fusion.

V.5 Conclusion

Dans ce chapitre nous avons présenté l'estimation des masses issues des différentes sources d'information. Nous avons eu à détailler l'approche d'extraction des couronnes d'arbre pour l'importance de cette source déduite de l'image haute résolution. En effet, les couronnes d'arbres seront utilisées comme attribut pour le calcul des masses sous formes de règles expert. A travers les couronnes extraites, on aura la possibilité de dégager des indices de formes que l'on applique pour l'estimation des fonctions de masse et pour définir les variables contextuelles qui permettent de réduire le nombre de sources dans le calcul des masses combinée.

CHAPITRE VI

**ARCHITECTURE D'UN SYSTEME DE FUSION DE
SOURCES D'INFORMATIONS BASÉ SUR LA
THEORIE DES FONCTIONS DE CROYANCE ET
APPLIQUÉ POUR LE CONTEXTE FORESTIER**

CHAPITRE VI

Architecture d'un système de fusion de sources d'informations basé sur la théorie des fonctions de croyance et appliqué pour le contexte forestier

VI.1 Introduction

Nous avons développé tout au long de cette thèse notre approche concernant le processus de classification d'images de télédétection dans un contexte multi sources. Nous avons introduit un système de fusion dont la vue d'ensemble a été présentée dans la figure VI.1. Ce système permet :

- La prise en compte de la nature de chaque source et la mise en correspondance avec une image de référence (inventaires forestiers).
- La définition du référentiel de définition qui sera retenu (RDR : Référentiel de Définition Réduit) avec une taille très inférieure à la taille du référentiel de définition conventionnelle. Ceci s'intègre dans la réduction de la complexité et donc dans la résolution du problème combinatoire.
- La détermination des hypothèses composées à partir des échantillons des classes (zones d'apprentissages) ce qui permet la détermination des éléments focaux composant le référentiel de définition réduit.
- L'exploitation de l'information spectrale et de texture pour les images source
- L'estimation des fonctions de masses cohérente avec les propriétés de l'image de télédétection haute résolution et de l'image des exposants de Hölder correspondante.
- Le choix des sources d'informations « utiles » pour chaque contexte (ce qui réduit le conflit entre les sources)
- L'intégration d'un algorithme d'extraction des couronnes pour des fins d'affinement du résultat de la classification et ceci afin d'obtenir une classification à l'arbre près.

Dans ce chapitre nous illustrons les étapes de notre système de fusion avec des exemples tout en évaluant visuellement et numériquement les résultats obtenus au niveau complexité et au niveau résultat de classification.

Nous commençons par l'illustration des étapes d'apprentissage, de détermination du RDR et de l'estimation des fonctions de masses sur des images moyenne et haute résolution de la zone d'étude. Nous passons dans une deuxième partie du chapitre à une évaluation globale de l'approche en la comparant à d'autres méthodes utilisant le formalisme probabiliste et à des méthodes n'intégrant pas le contexte.

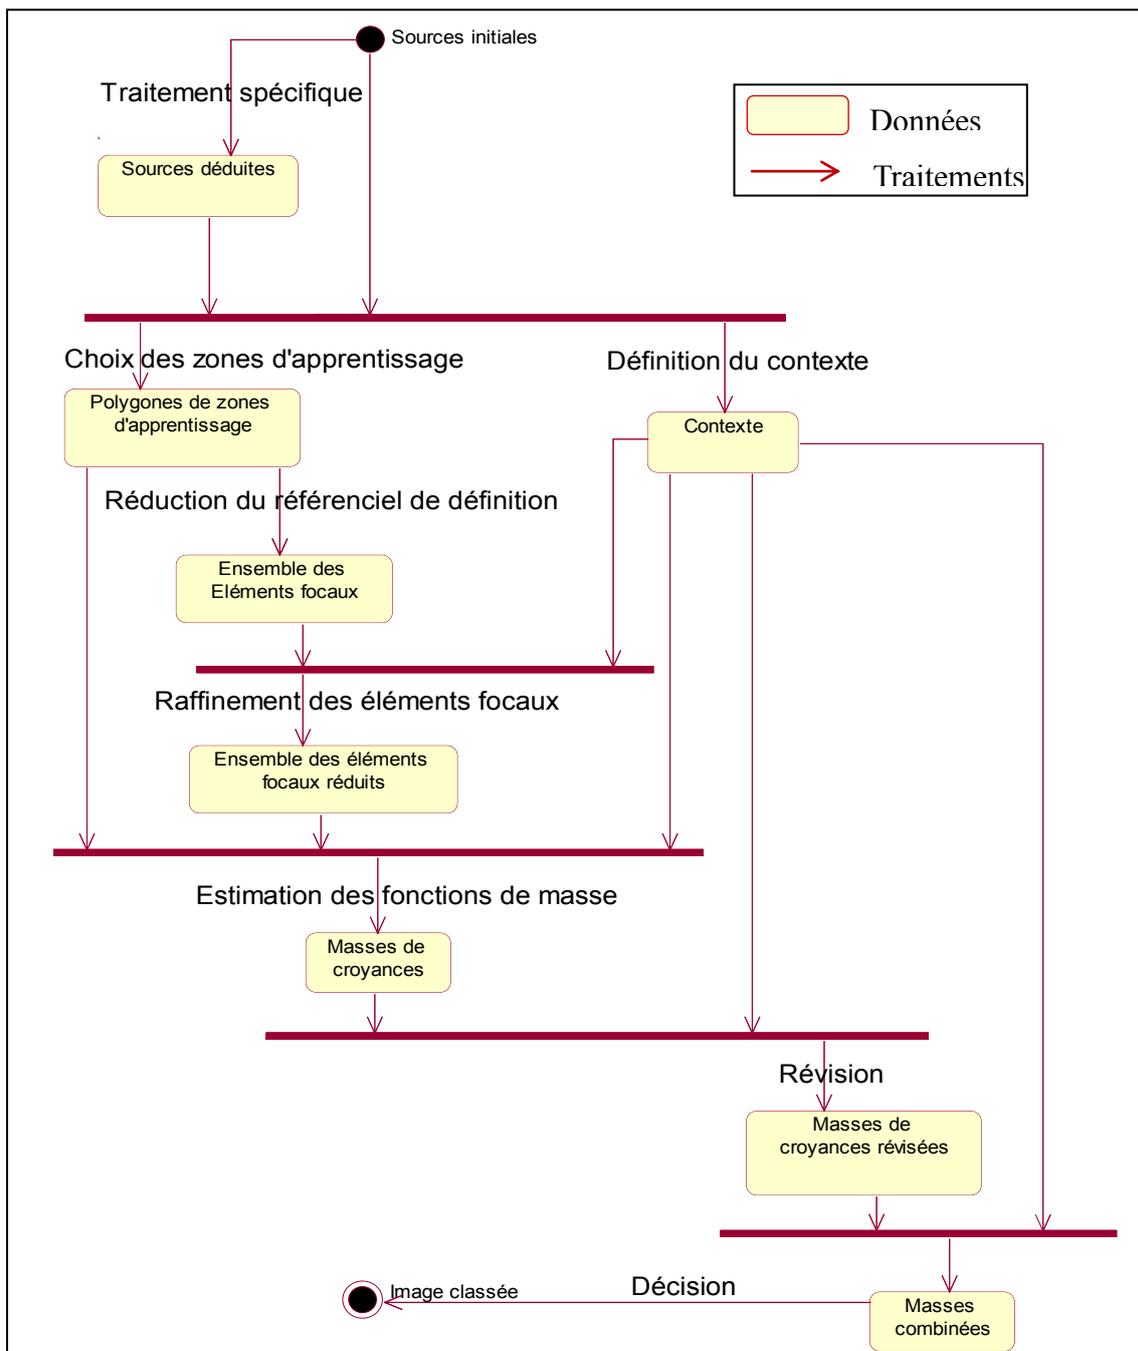


Figure VI.1. Architecture de notre système de fusion

VI.2 Apprentissage

La cartographie des images de télédétection s'appuie en général sur une approche de classification supervisée. Les classes d'occupation sont à priori définies à travers des zones d'apprentissage qui correspondent à l'inventaire numérisé en strates. Toutefois, pour l'image haute résolution, on a eu recours à des spécialistes du terrain pour définir quelques classes dont la correspondance avec l'inventaire numérisé était problématique. En effet, l'inventaire numérisé apporte souvent une information globale sur l'espèce dominante et informe souvent sur des mélanges d'espèces. C'est le cas des deux classes chêne liège et chêne zen qui figurent souvent avec un même label dans l'inventaire numérisé à cause de sa faible résolution.

Pour chaque classe on a eu donc à définir des zones d'apprentissage sous forme de polygones et à former ainsi une base d'apprentissage qui sera utilisée pour la caractérisation de chaque type d'occupation du sol.

VI.2.1 Source d'information image moyenne résolution SPOT

La première source impliquée dans le processus de fusion est l'image moyenne résolution Spot de notre zone d'étude. La figure VI.2 (a) illustre une vue de la bande PIR de cette image multi-spectrale avec les zones d'apprentissages choisies pour les neuf classes de l'image. La figure VI.2 (b) illustre l'inventaire (coloré en types) qui a été choisi comme référence pour le choix des zones d'apprentissage. La mise en correspondance de l'inventaire avec l'image moyenne résolution permet de faciliter le choix des échantillons des classes.



(a) L'IMR (Spot) de la zone d'étude



(b) : IFN de la zone d'étude

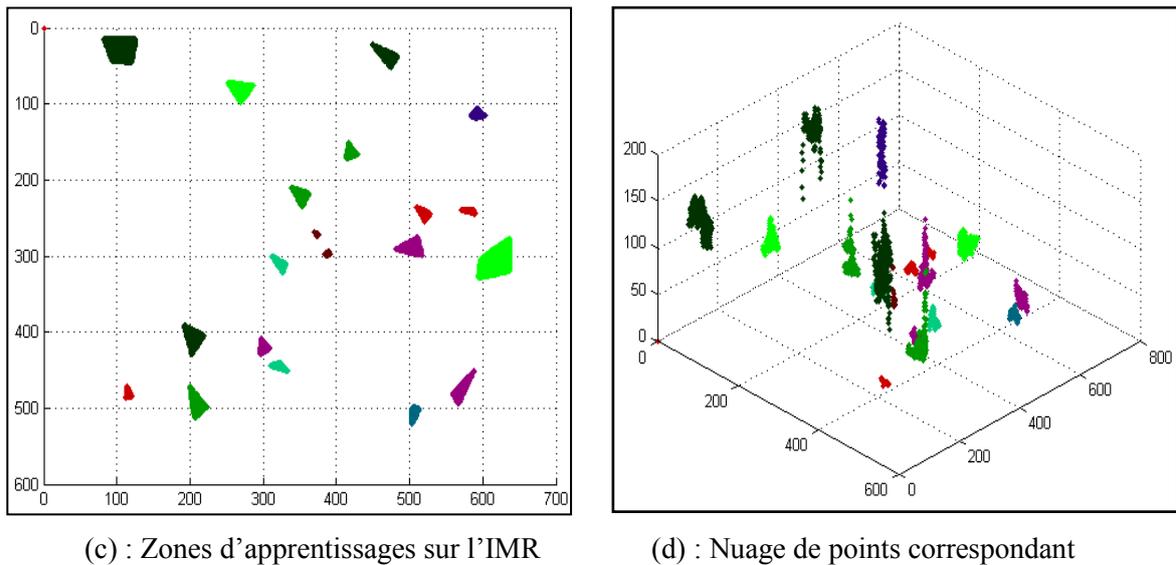


Figure VI.2. Image Spot de la zone d'étude, IFN et choix des zones d'apprentissage.

VI.2.1.1 Choix des échantillons sur la base de l'inventaire

La figure VI.3(c) montre les polygones correspondants aux zones d'apprentissage que nous avons choisies sur notre image Spot moyenne résolution (IMR).

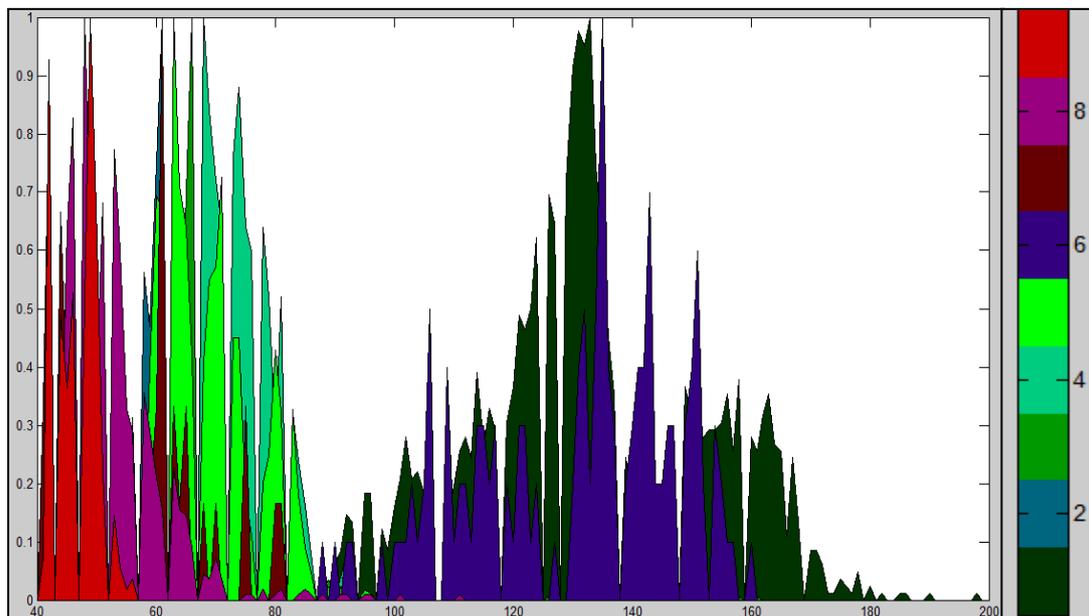


Figure VI.3. Histogrammes des zones d'apprentissages des classes choisies sur l'IMR.

Les classes correspondantes à ces zones d'apprentissages sont 9 classes correspondantes aux différentes espèces qui coexistent dans notre zone d'étude. Le cadre de discernement s'écrit ainsi : $\Omega = \{C_1, C_2, C_3, C_4, C_5, C_6, C_7, C_8, C_9\}$, avec : C_1 = Sol très peu couvert; C_2 = Pins divers; C_3 = Chêne liège ; C_4 = Chêne vert ; C_5 = Chêne zen; C_6 = Cyprés; C_7 = Eucalyptus; C_8 = Pin maritime; C_9 = Pin pignon.

La faible résolution de l'image Spot ainsi que la réponse radiométrique des classes d'occupation ont comme conséquences plusieurs chevauchements entre classes que l'on illustre par les figures VI.2(d) et VI.3. En effet, ces figures montrent des plages de niveau de gris partagées entre plusieurs classes, ce qui renforce la confusion radiométrique pour des types de formations forestières. L'histogramme normalisé de la figure VI.3 montre la limite de l'image moyenne résolution à pouvoir identifier l'ensemble des classes définies.

VI.2.1.2 Image de Hölder

Comme nous l'avons déjà présenté dans le chapitre V, l'information de texture a été extraite à partir des exposants de singularités formant l'image de Hölder. L'image de Hölder correspondante à la fenêtre de l'IMR est illustrée dans la figure VI.4(a). L'analyse de l'histogramme des exposants de singularité (figure VI.4(b)) pour les zones d'apprentissage illustre l'importance de l'image de Hölder en tant que source d'information. En effet, comparé à l'histogramme des niveaux de gris (figure VI.3), les chevauchements entre classes se trouvent plus limités et ce par le renforcement de l'homogénéité locale apporté par les exposants de singularité.

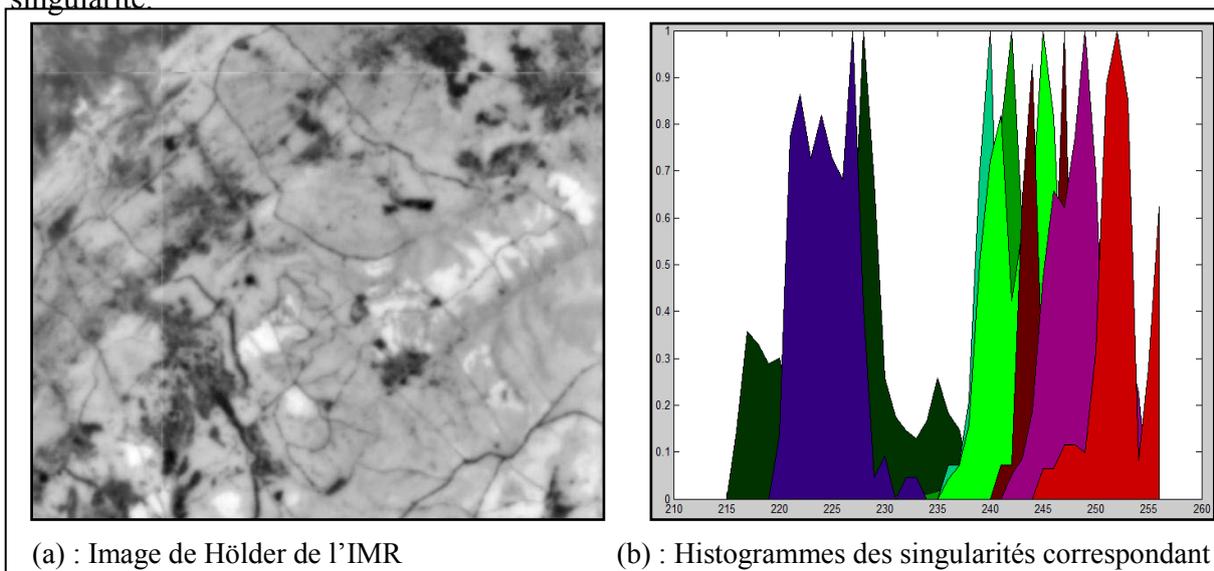


Figure VI.4. Image de Hölder obtenue à partir de l'IMR et histogramme des exposants de singularités des zones d'apprentissage correspondants.

VI.2.2 Source d'information image haute résolution QuickBird

Pour illustrer nos résultats sur l'image haute résolution (IHR), notre choix s'est concentré sur deux fenêtres de l'IHR contenant les espèces les plus présentes dans la scène traitée. Pour des traitements spécifiques tels que la détermination de l'image de Hölder ou l'extraction des couronnes, nous avons utilisé des sous-fenêtres de taille plus petite pour mieux présenter les résultats. Ainsi, nous avons en tout 6 fenêtres que nous numérotons de 1 à 6.

Fenêtre 1

La figure VI.5(a) montre la fenêtre 1 de l'image haute résolution (IHR) extraite de notre image QuickBird de la zone d'étude, l'inventaire numérisé de la zone correspondante et une projection des contours de l'inventaire numérisé sur la fenêtre image sont illustrés respectivement par les figures VI.5(b) et VI.5(c). Les classes d'occupation inventoriées correspondent essentiellement aux formations suivantes :

- Forêt de résineux
- Infrastructures
- Chêne liège
- Chêne zen
- Mélange de feuillus et résineux
- Mélange chêne liège et chêne zen

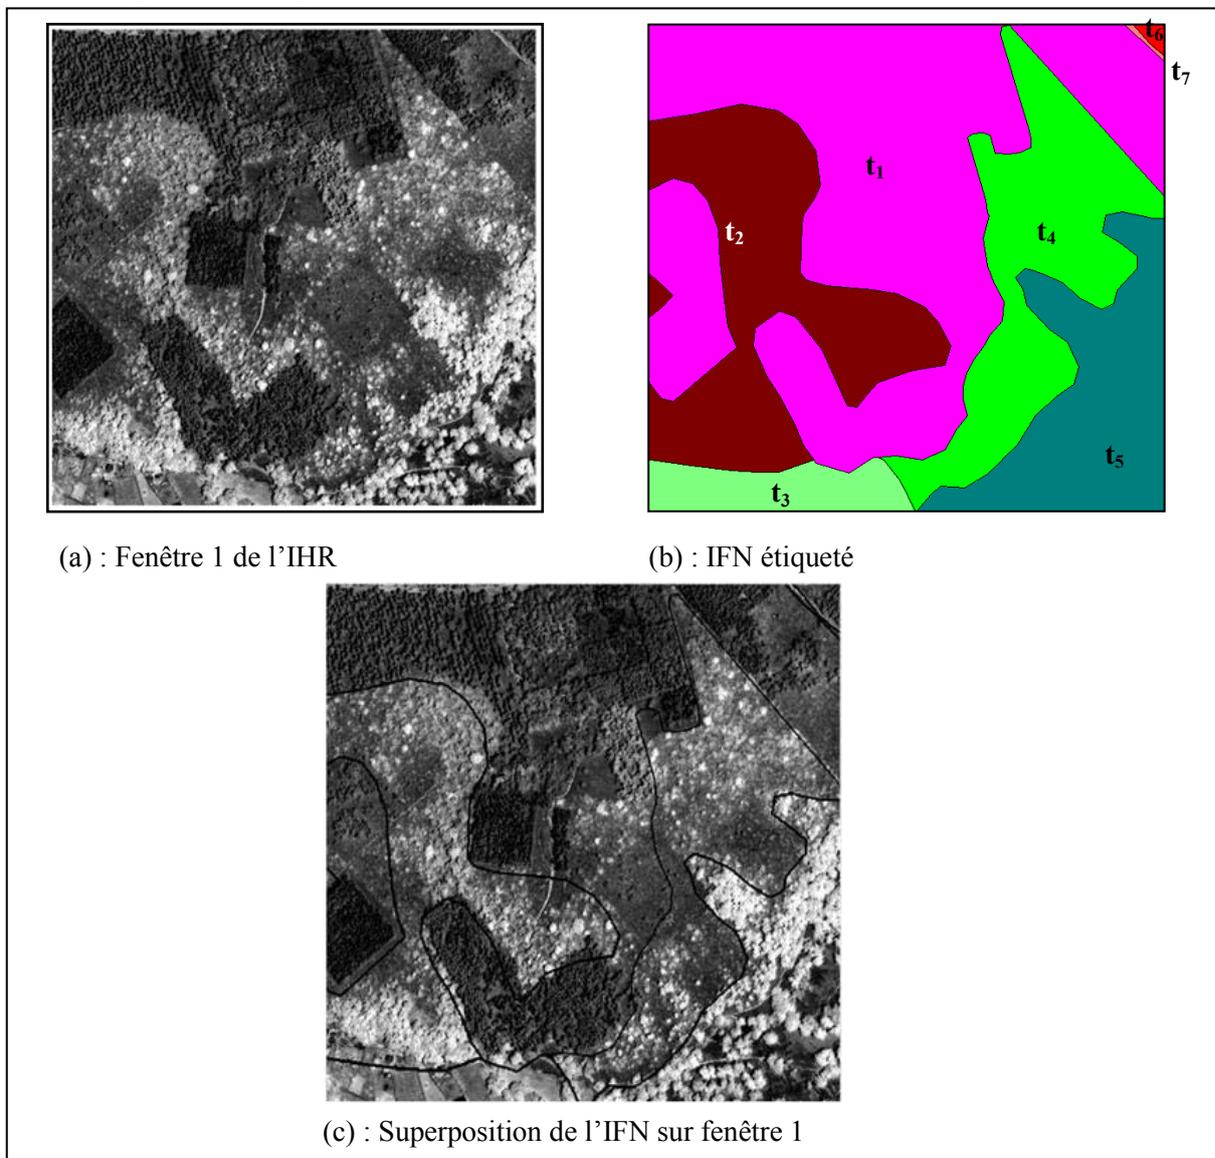


Figure VI.5. Fenêtre 1 de l'IHR QuickBird et IFN correspondant.

On remarque que l'inventaire forestier n'apporte pas toujours une information détaillée sur l'espèce d'arbre puisque plusieurs polygones sont classés à des mélanges d'espèces différentes. Ceci s'explique par la résolution faible de l'inventaire numérisé et la difficulté de décomposer en polygones de petites surfaces des zones de formations mixtes. En effet, nous avons pu associer les polygones (étiquetés) de la figure VI.5(b) aux strates et types suivants :

t_1 : Arboretum, type : mélange feuillis et résineux

t_2 : Forêt de feuillis : chêne liège + chêne zen

t_3 : Zone agro forestière

t_4 : Forêt de feuillis - chêne liège

t_5 : Forêt de feuillis - chêne zen

t_6 : Forêt de résineux

t_7 : Infrastructures

VI.2.2.1 Choix des zones d'apprentissage

La figure VI.6 correspond à une deuxième fenêtre (fenêtre 2) extraite de notre image QuickBird, l'inventaire correspondant et des zones d'apprentissage pour les formations de l'occupation du sol.

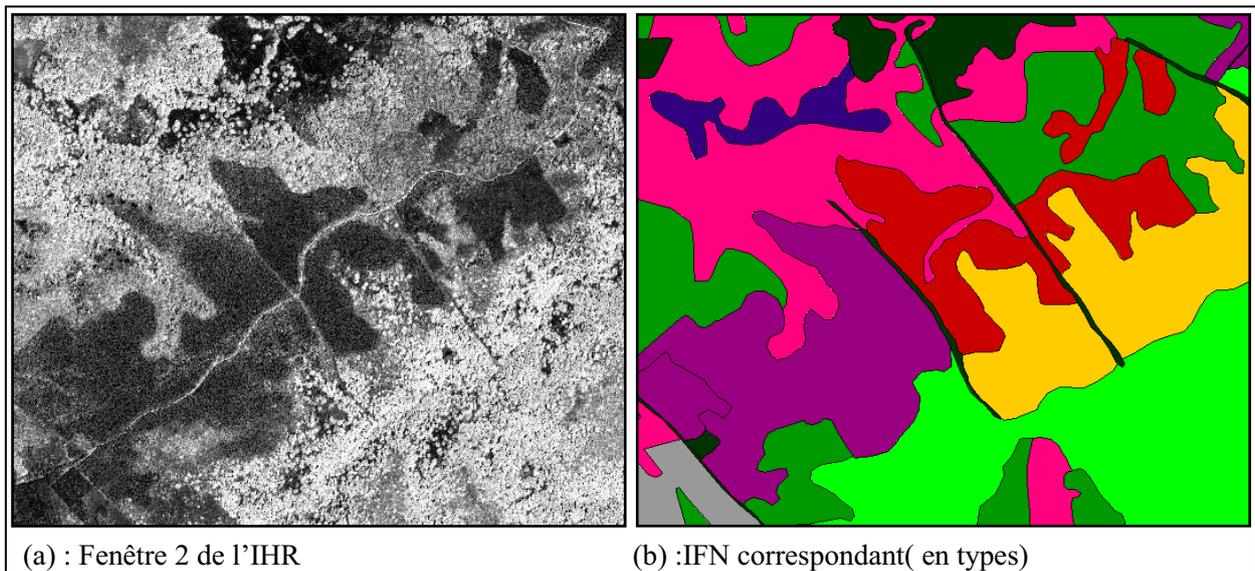


Figure VI.6. Fenêtre 2 de l'image haute résolution et IFN correspondant

Les strates relatives aux formations indiquées au niveau de l'inventaire forestier sont les suivantes :

- Forêt mixte
- Pin pignon
- Pin maritime
- Chêne liège

- Chêne zen
- Arboretum
- Cyprès
- Mélange chêne liège et chêne zen

On remarque encore une fois un classement mixte des classes d'occupation chêne liège et chêne zen au niveau de l'inventaire. La figure VI.7 présente des zones d'apprentissage choisies sur la fenêtre 2 et l'histogramme correspondant. La distribution des niveaux de gris informe sur quelques plages de niveaux identiques pour la plupart des classes (pin pignon-pin maritime, chêne liège-chêne zen etc.).

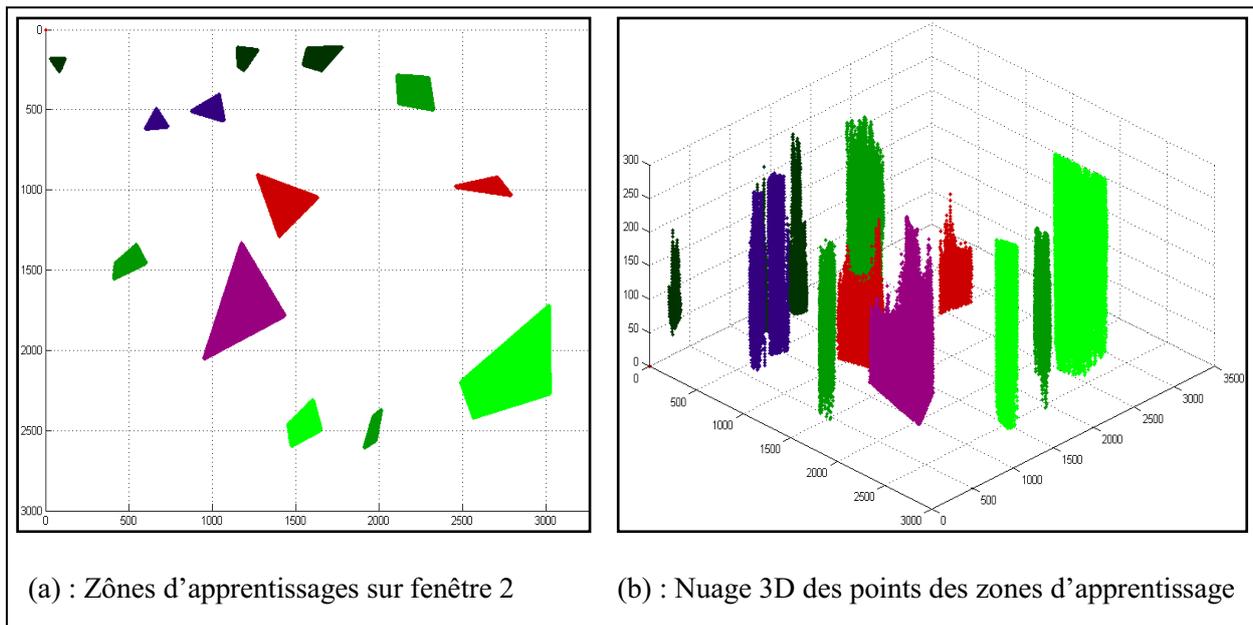


Figure VI.7. Zones d'apprentissages choisies sur la fenêtre2 de l'IHR.

La figure VI.8(a) présente la fenêtre 3 qui n'est qu'une partie de notre IHR extraite de la fenêtre 2 et qui fait apparaître la difficulté de départager avec l'information radiométrique les deux classes pin pignon et pin maritime (figure VI.8.b) qui ont des niveaux de gris comparables comme le montre l'histogramme des zones d'apprentissage des classes choisies de la figure VI.8(c).

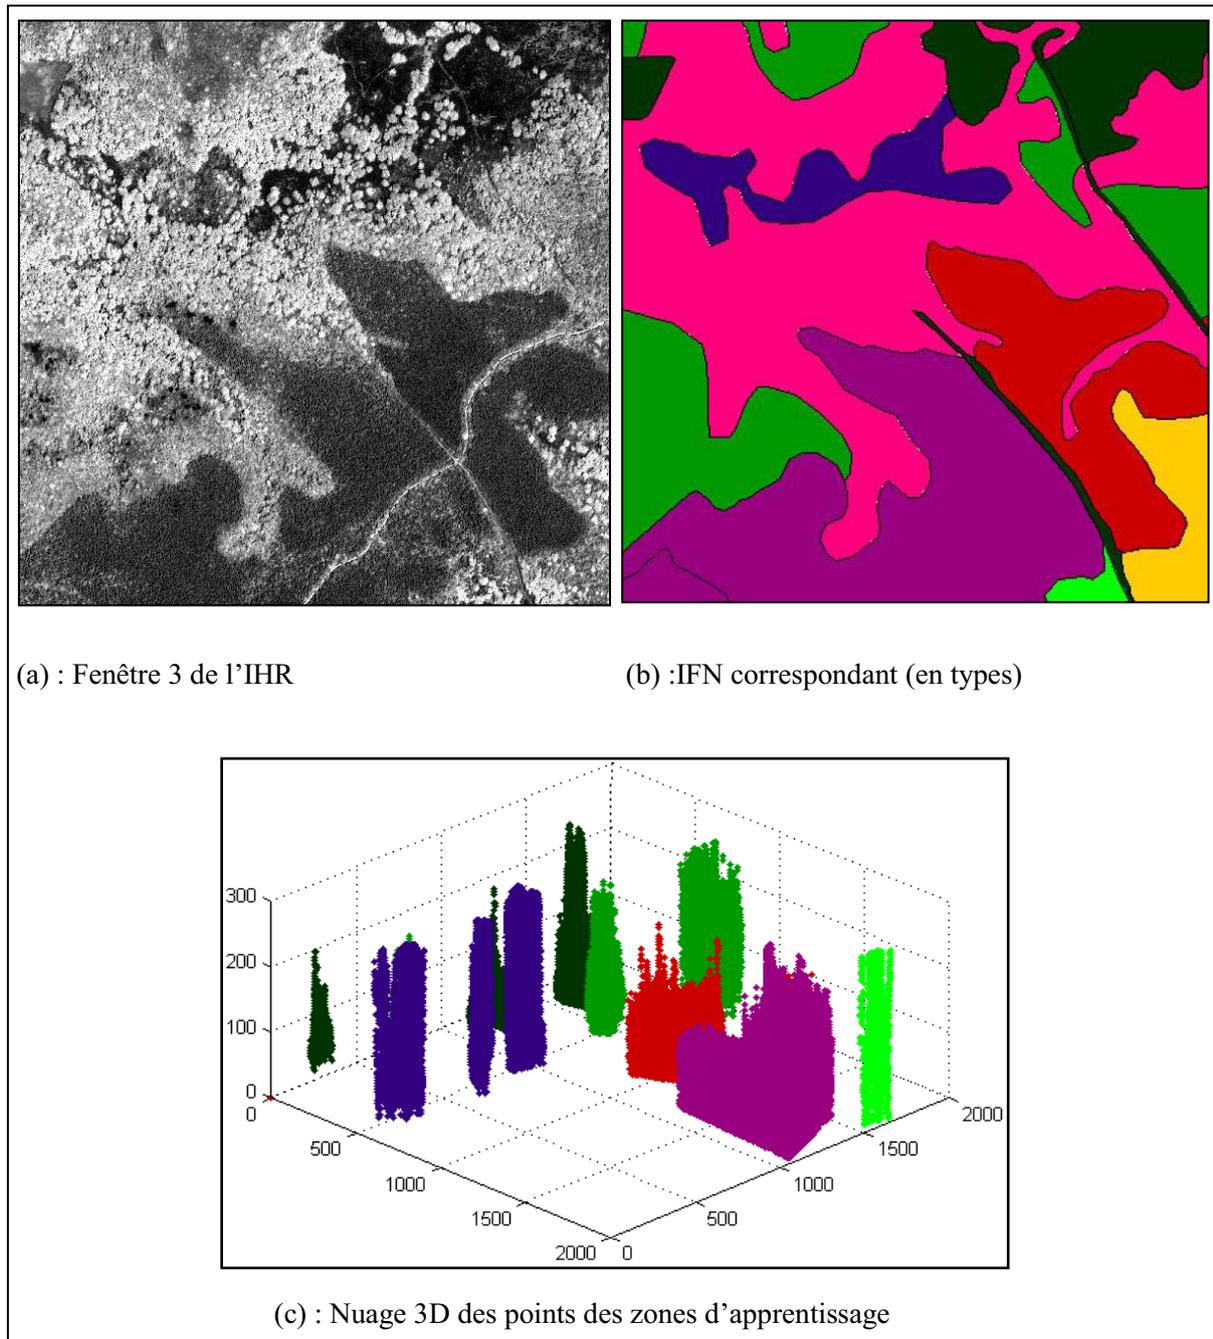
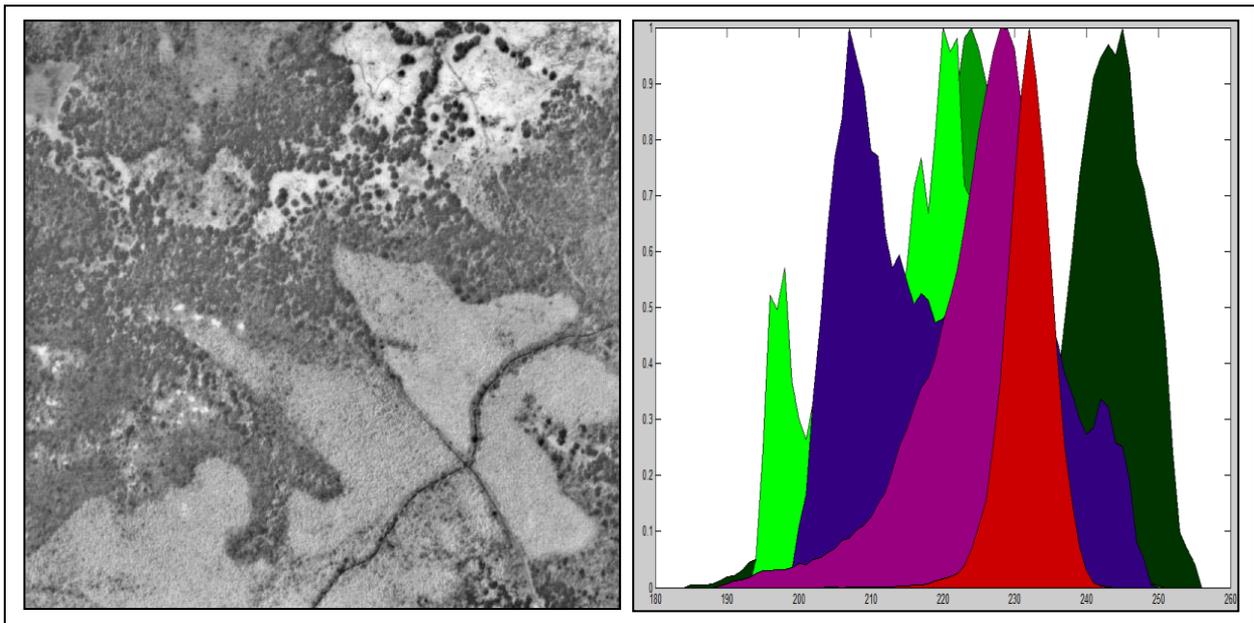


Figure VI.8. Fenêtre 3 de l'IHR ainsi que son IFN et le choix des zones d'apprentissage.

VI.2.2.2 Image de Hölder

La figure VI.9 (a) représente l'image de Hölder obtenue à partir de la fenêtre 3 de notre IHR (comme détaillée dans la section V.3 du chapitre précédent) ainsi que l'histogramme correspondant (figure VI.9(b)).



(a) : Image de Hölder de la fenêtre 3 de l'IHR (b) : Histogrammes des singularités correspondant

Figure VI.9. Image de Hölder obtenue à partir de la fenêtre 3 de l'IHR et les histogrammes des exposants de singularités des zones d'apprentissage correspondantes.

VI.3 Illustration de la réduction du référentiel de définition

Une étape importante de notre système de classification consiste à définir le référentiel de définition réduit composé exclusivement pas les éléments focaux. Ce qui permet de minimiser le nombre d'opérations de calcul des fonctions de masse en calculant, seulement, les masses des éléments focaux déterminés dans l'étape de réduction, comme détaillée dans le chapitre IV. Nous illustrons dans cette section l'apport de notre méthode de réduction du référentiel de définition sur deux exemples correspondant aux fenêtres 1 et 2 extraites de l'IHR (présentées dans la section précédente).

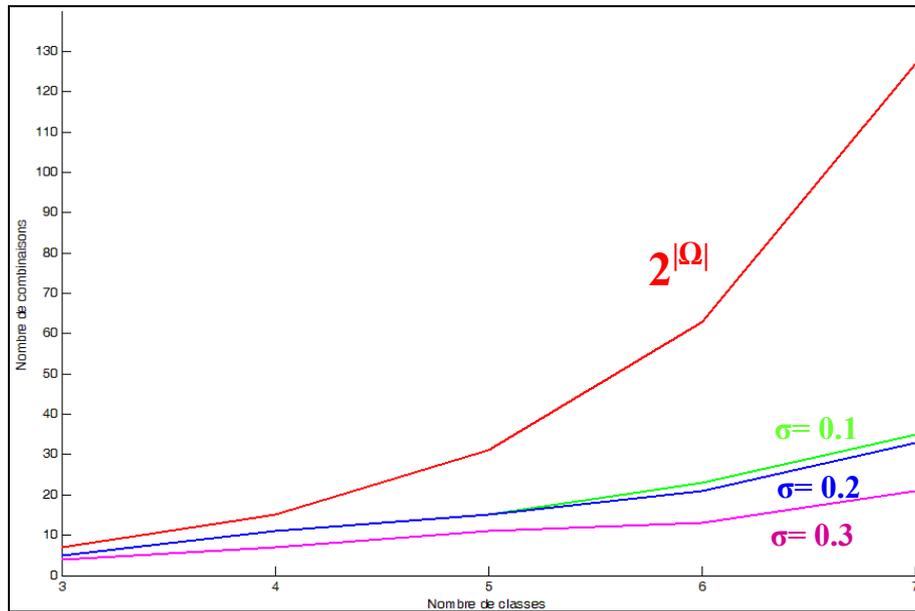
VI.3.1 Choix des hypothèses du cadre de discernement

Dans les exemples que nous présentons, le cadre de discernement Ω représente les classes d'occupations forestières. Il a été déduit à partir de l'inventaire forestier qui apporte une liste exhaustive de l'ensemble des classes d'occupation du sol.

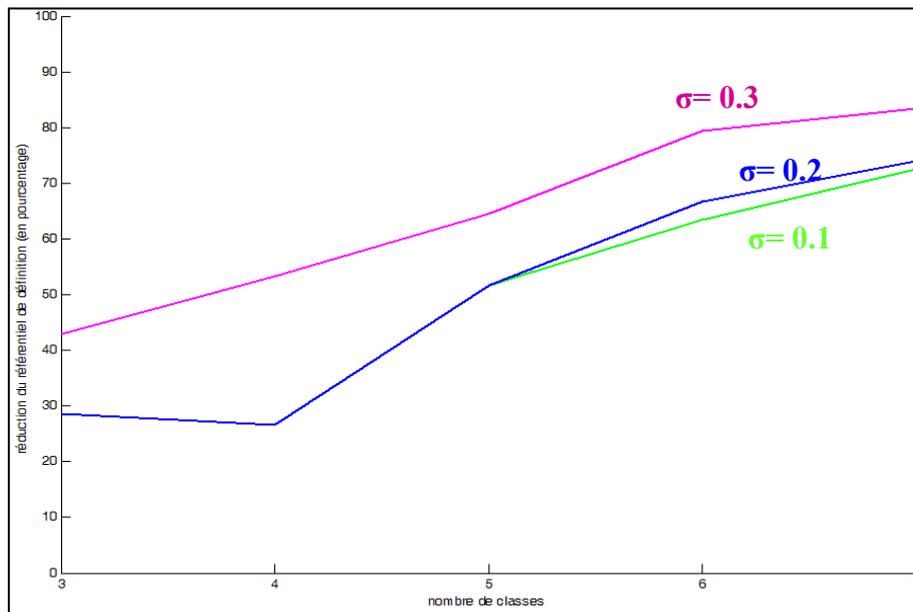
VI.3.2 Apport au niveau complexité temporelle

Les figures VI.10(a) et VI.11(a) illustrent le gain en nombre de combinaisons et en pourcentage que l'on dégage à travers la réduction du référentiel de définition. Ces figures ont été dégagées à partir de tests appliqués sur les fenêtres 1 et 2 de l'IHR et en se basant sur cinq et sept classes correspondantes respectivement aux figures VI.5 et VI.6. Pour sept classes, on arrive à réduire la taille du référentiel de 70% à 80% en diminuant la limite du pourcentage de

chevauchement tolérée pour retenir l'hypothèse composée correspondante en tant qu'élément focal. Ce résultat est important et permet de réduire considérablement le temps d'exécution nécessaire pour l'évaluation des masses des combinaisons.

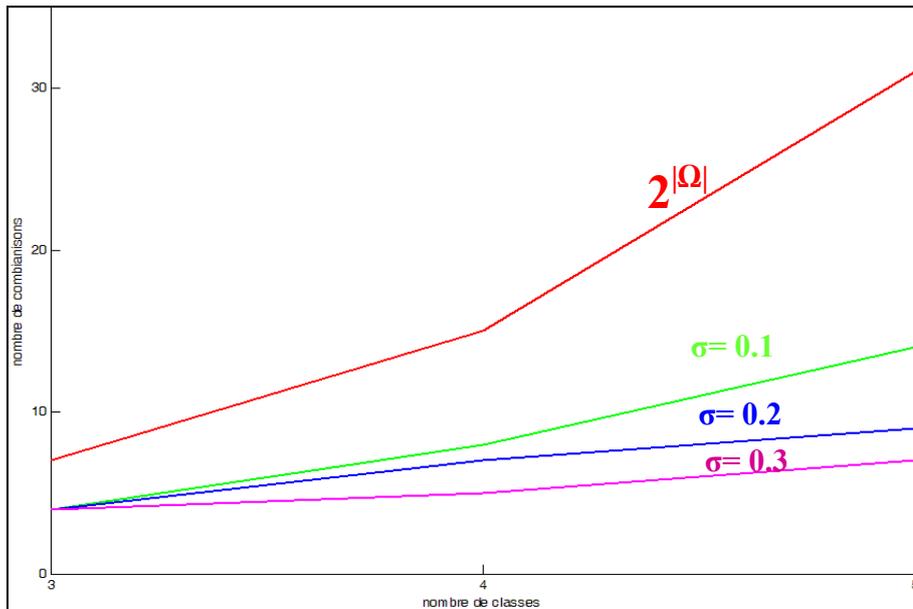


(a) : Courbe du nombre de combinaisons en fonction du nombre de classes avec variation du seuil

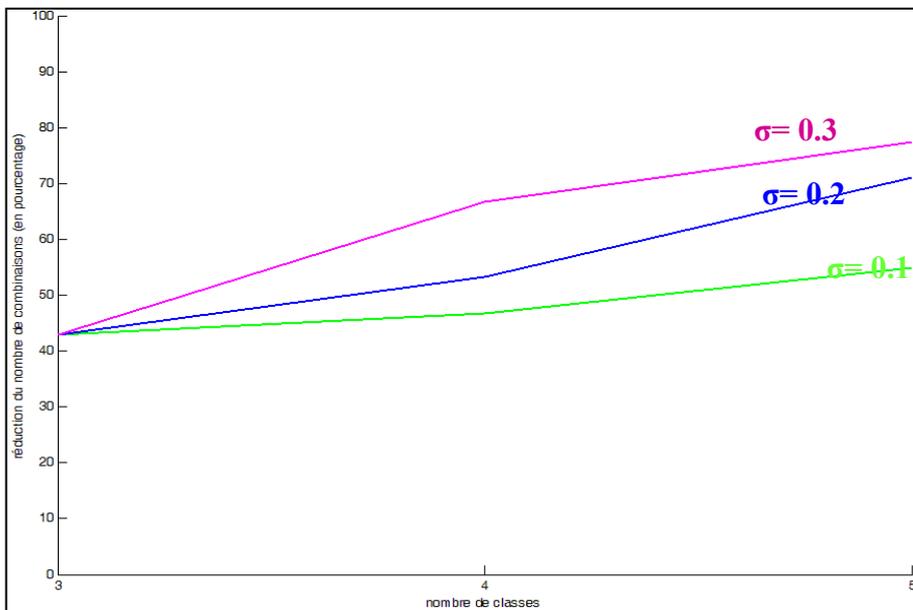


(b) : Pourcentage de réduction de la cardinalité du référentiel de définition en fonction du nombre de classes avec variation du seuil

Figure VI.10. Courbes de réduction du référentiel de définition en fonction du seuil correspondantes à la fenêtre 2.



(a) : Courbe du nombre de combinaisons en fonction du nombre de classes avec variation du seuil



(b) : Pourcentage de réduction de la cardinalité du référentiel de définition en fonction du nombre de classes avec variation du seuil

Figure VI.11. Courbes de réduction du référentiel de définition en fonction du seuil correspondantes à la fenêtre 1.

VI.4 Classification et estimation des fonctions de masse de l'IMR

Dans cette section, nous présentons des exemples illustratifs de nos méthodes d'estimations des fonctions de masse sur l'IMR moyennant les histogrammes de niveaux de gris et de singularités. Nous présentons aussi les résultats de la classification ainsi obtenus. L'évaluation des performances du système de classification (supervisée) est effectuée en premier lieu par la matrice de confusion calculée directement sur les données d'apprentissage. Cette matrice permet de mesurer le niveau d'accord entre la classification obtenue et la vérité

terrain (à travers les classes réelles d'appartenance des échantillons correspondants aux données d'apprentissage). Elle représente l'affectation des échantillons (classes réelles correspondantes à la vérité terrain) dans les classes estimées (ou classes d'affectations). Chaque ligne de cette matrice décrit la répartition d'un échantillon d'une classe réelle sur les différentes classes estimées et chaque colonne décrit la répartition d'une classe estimée sur les classes réelles. Nous présentons dans ce rapport nos matrices de confusion en termes de pourcentages.

Rappelons, tout d'abord les classes correspondantes aux zones d'apprentissages choisies sur notre IMR tels que décrits dans le paragraphe VI.2.1.1: C_1 = Sol très peu couvert (SPC); C_2 = Pins divers (Pins); C_3 = Chêne liège (CL); C_4 = Chêne vert (CV); C_5 = Chêne zen (CZ); C_6 = Cyprès (Cyp); C_7 = Eucalyptus (Euc); C_8 = Pin maritime (PM); C_9 = Pin pignon (PP).

VI.4.1 Estimation des fonctions de masse à travers les histogrammes de niveaux de gris

La figure VI.12 présente le résultat de la classification de l'image Spot de toute la zone d'étude et ce à partir des masses définies pour les zones d'apprentissages. Ce résultat est évalué à travers la matrice de confusion du tableau VI.1.

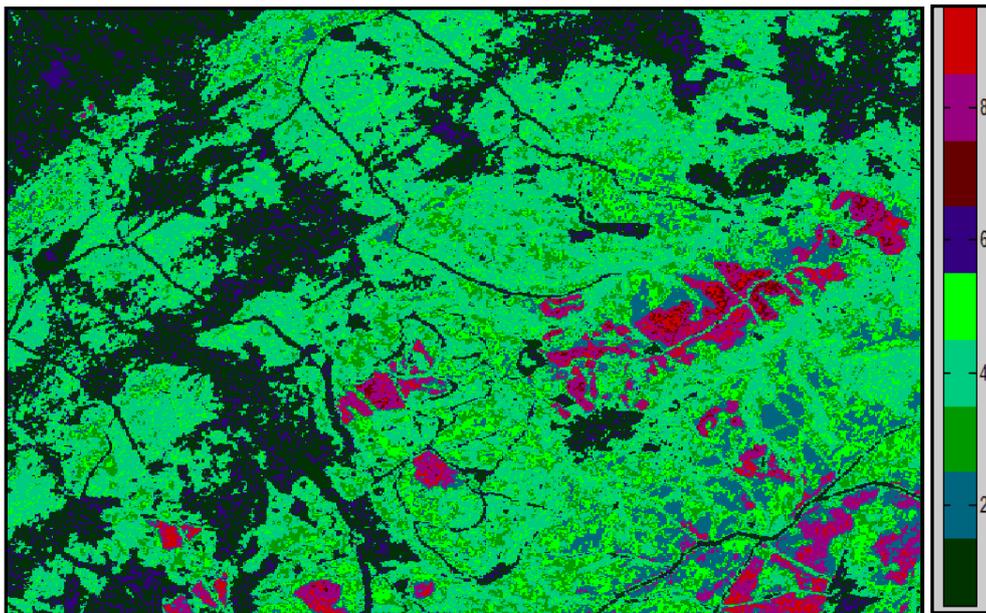


Figure VI.12. Classification spectrale par maximum de masse de l'image moyenne résolution.

L'analyse de la diagonale de la matrice de confusion du tableau VI.1 ainsi que le faible indice kappa conséquent (0.45) révèlent l'incapacité de l'image Spot à départager des classes d'occupation de réflectances assez voisines et d'apporter une information détaillée en classes. La confusion atteint son maximum avec la classe C_7 (Eucalyptus) qui se trouve mélangée avec les classes C_2 , C_8 et C_9 (les classes de pins). Toutefois, l'Eucalyptus n'est pas une espèce dominante dans la zone d'étude et la confusion entre les classes CL, CZ et CV d'une part, et les classes de pins (C_2 , C_8 et C_9) demeure le problème majeur de la classification spectrale basée sur l'IMR. Les figures VI.13(a) et VI.13(b) illustrent les zones d'apprentissages retenues pour les neuf classes. Tandis que les figures VI.13(b) et VI.13 (c) illustrent la dispersion des niveaux

de gris associés à ces classes ainsi que le résultat de leurs affectations par maximum de masse.

Classes réelles \ Classes estimées	SPC	Pins	CL	CV	CZ	Cyp	Euc	PM	PP
SPC	82.26	0	0	0.11	0.05	17.58	0	0	0
Pins	0	68.28	5.52	1.38	19.31	0	0	5.52	0
CL	3.24	1.5	34.45	39.77	19.88	1.16	0	0	0
CZ	2.76	0.39	5.12	74.80	16.93	0	0	0	0
C5	0.89	18.47	10.70	37.67	31.64	0.58	0	0.5	0
Cyp	50	0	0	0	0	50.00	0	0	0
Euc	0	23.91	4.35	10.87	8.70	0	13.04	21.74	17.14
PM	0.64	15.28	2.78	2.88	5.02	0.11	3.10	57.05	13.14
PP	0	0.73	0	0	0	0	11.31	36.66	51.09

Tableau VI.1. Matrice de confusion de la classification spectrale par maximum de masse de l'image moyenne résolution.

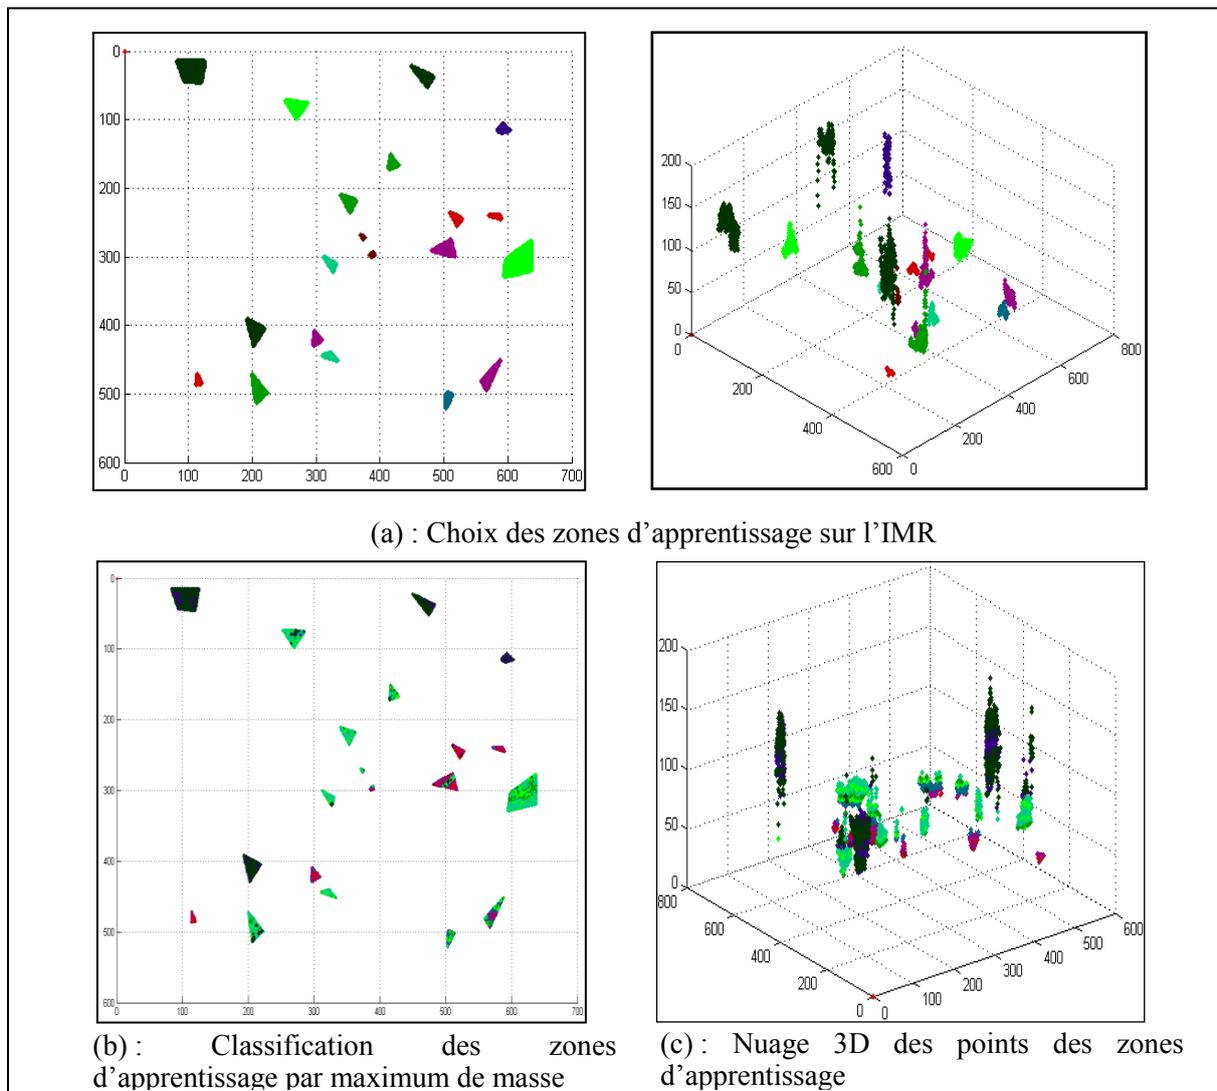


Figure VI.13. Classification spectrale par maximum de masse des échantillons choisis sur l'IMR.

VI.4.2 Estimation des fonctions de masse à travers les histogrammes des exposants de singularités

La figure VI.14 illustre le résultat de la classification de l'IMR en se basant sur les histogrammes de Hölder. L'information de texture dégagée à partir de l'image des exposants de singularités améliore l'indice Kappa de la matrice de confusion qui passe de 0.45 pour la classification spectrale à 0.56 pour la classification texturale.

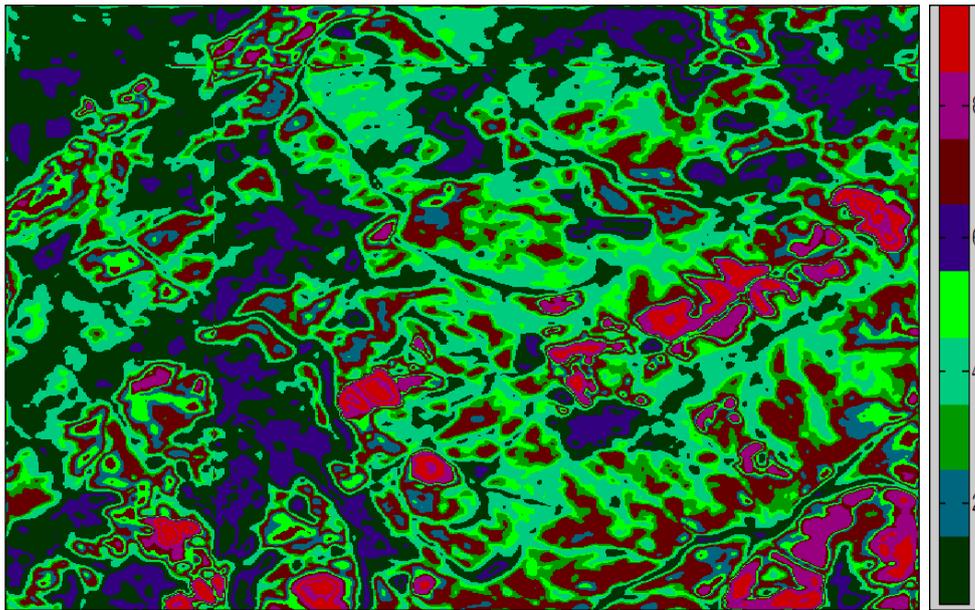


Figure VI.14. Classification de l'image de Hölder de l'IMR par maximum de masse.

Classes réelles \ Classes estimées	SPC	Pins	CL	CV	CZ	Cyp	Euc	PM	PP
SPC	72.58	0	0	1	0	26.42	0	0	0
Pins	0	66.90	0	0	6.21	0	26.90	0	0
CL	3.24	11.79	20.58	6.94	22.77	0	34.68	0	0
CZ	5.51	0	11.02	72.05	11.02	0	0.39	0	0
C5	1.84	16.47	6.98	22.77	26.92	0	25.03	0	0
Cyp	12.14	0	0	0	0	0	87.86	0	0
Euc	0	6.52	2.17	0	13.04	0	78.26	0	0
PM	0	8.65	0.96	0	12.07	0	16.45	49.57	12.29
PP	0	1.46	0	0	1.46	0	2.55	13.50	81.02

Tableau VI.2. Matrice de confusion de la classification texturale par maximum de masse de l'IMR.

VI.5 Exploration de l'IHR : Estimation des masses et révision

Nous présentons dans cette section une étude plus complète sur l'image haute résolution étant donnée la richesse de l'information qu'elle fournit. En effet, les étapes de révision par l'information couronne et structurelle seront illustrés sur différentes fenêtres de l'IHR.

VI.5.1 Estimation des fonctions de masse à travers les histogrammes

Nous présentons ici les résultats de la classification par maximum de masses de l'IHR à partir des informations spectrales ensuite avec l'information de texture.

VI.5.1.1 Estimation des masses à partir des histogrammes de niveaux de gris

- Fenêtre 3 : Fenêtre 2000*2000 de l'IHR

La figure VI.15(b) illustre le résultat de la classification d'une fenêtre 2000*2000 de l'IHR. Les espèces dégagées sur cette fenêtre sont six classes : $\Omega = \{C1 : \text{Pin Pignon (PP)}, C2 : \text{Pin Maritime (PM)}, C3 : \text{Chêne Zen (CZ)}, C4 : \text{Chêne Liège (CL)}, C5 : \text{Sol Peu Couvert (SPC)}, C6 : \text{Sol Nu (SN)}\}$. Le choix des zones d'apprentissages correspondantes sont présentées par la figure VI.15(a). L'analyse de la matrice de confusion du tableau VI.3 montre une confusion entre le pin maritime et pin pignon d'une part, et entre chêne zen et chêne liège d'autre part, ce qui explique la faible valeur de l'indice kappa égale à 0,5 et la valeur de la moyenne de la diagonale égale à 58%.

Classes estimées \ Classes réelles	PP	PM	CZ	CL	SPC	SN
PP	66.27	9.42	0	0	22.77	1.53
PM	49.80	20.62	0	0.24	14.78	14.55
CZ	1.19	1.67	53.81	38.81	0	4.52
CL	2.55	3.92	12.37	65.82	0.12	15.23
SPC	31.45	1.02	0	0	66.93	0.6
SN	0.06	6.73	0	17.85	0	75.35

Tableau VI.3. Matrice de confusion de la classification spectrale par maximum de masse de la fenêtre 3 de l'IHR.

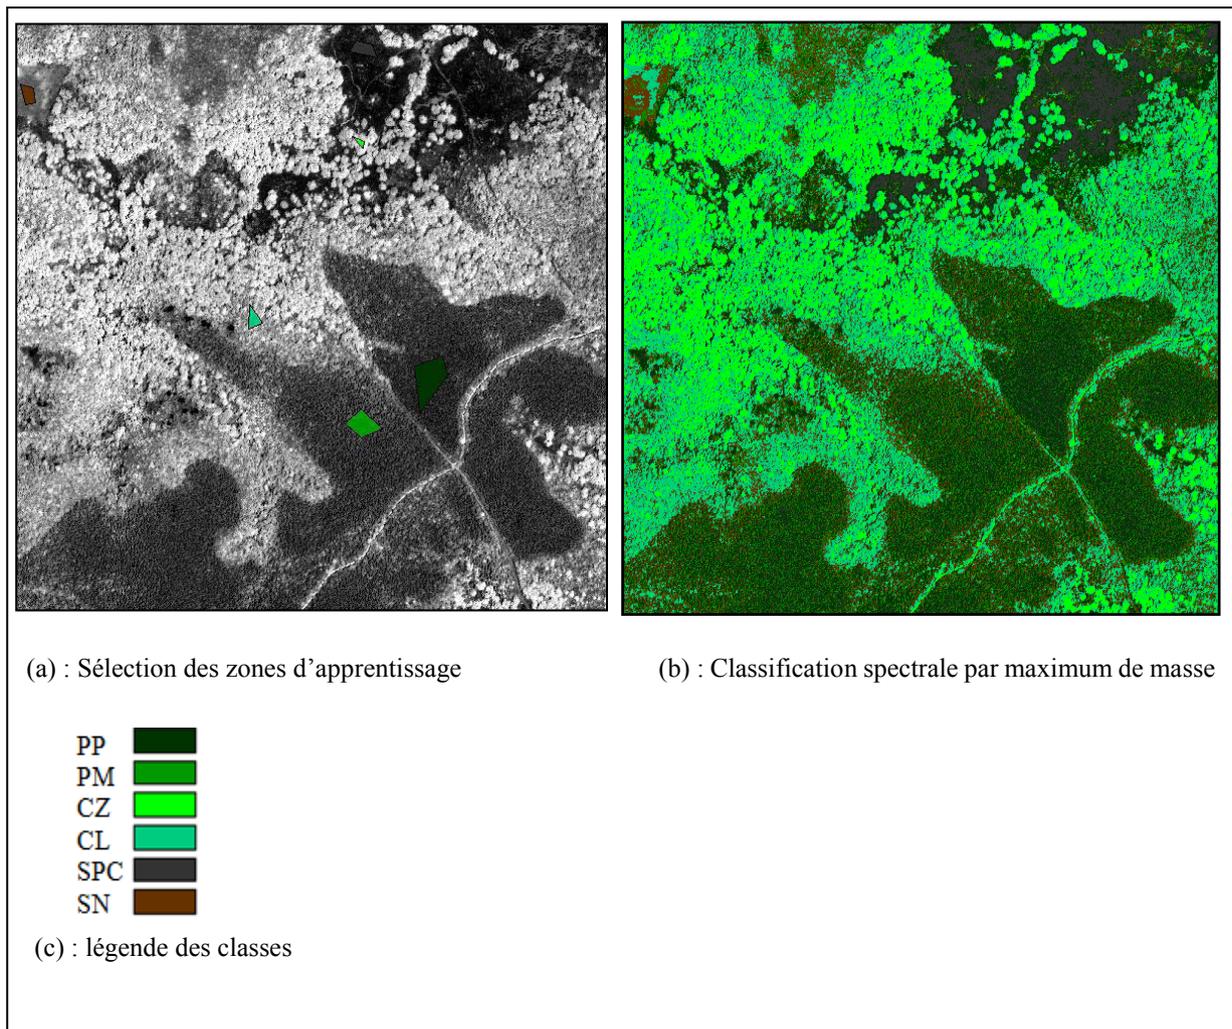


Figure VI.15. Choix des zones d'apprentissages et classification spectrale par maximum de masse de la fenêtre 3 de l'IHR.

-Fenêtre 4 : 300*300

La figure VI.16 (e) illustre le résultat de la classification de la fenêtre 4 l'IHR présentée en résolution réelle dans la figure VI.16(a). L'inventaire numérisé (figure VI.16(b)) comparé à l'image confirme qu'il a été réalisé de manière globale et n'informe pas donc de manière précise sur les classes d'occupations. Ce décalage s'explique par la faible résolution de l'inventaire par rapport à l'IHR ou par l'accroissement dans le temps de la forêt (référentiel temporel différent).

Le résultat révèle une grande confusion entre les deux espèces chêne liège (CL) et chêne zen (CZ). Aussi, quelques pixels de ces deux classes persistent sur les autres classes (classes non forestières). Les lignes et colonnes (les classes) de la matrice de confusion présentée dans le tableau VI.4 représentent les classes de 3 à 6 du cadre de discernement Ω , vu que seulement ces 4 classes sont présentes dans la fenêtre 4.

Classes réelles \ Classes estimées	CZ	CL	SPC	SN
CZ	92	8	0	0
CL	10.91	60	21.82	7.27
SPC	0	3.28	96.72	0
SN	0	5.05	0	94.95

Tableau VI.4. Matrice de confusion de la classification spectrale par maximum de masse de la fenêtre 4 de l'IHR.

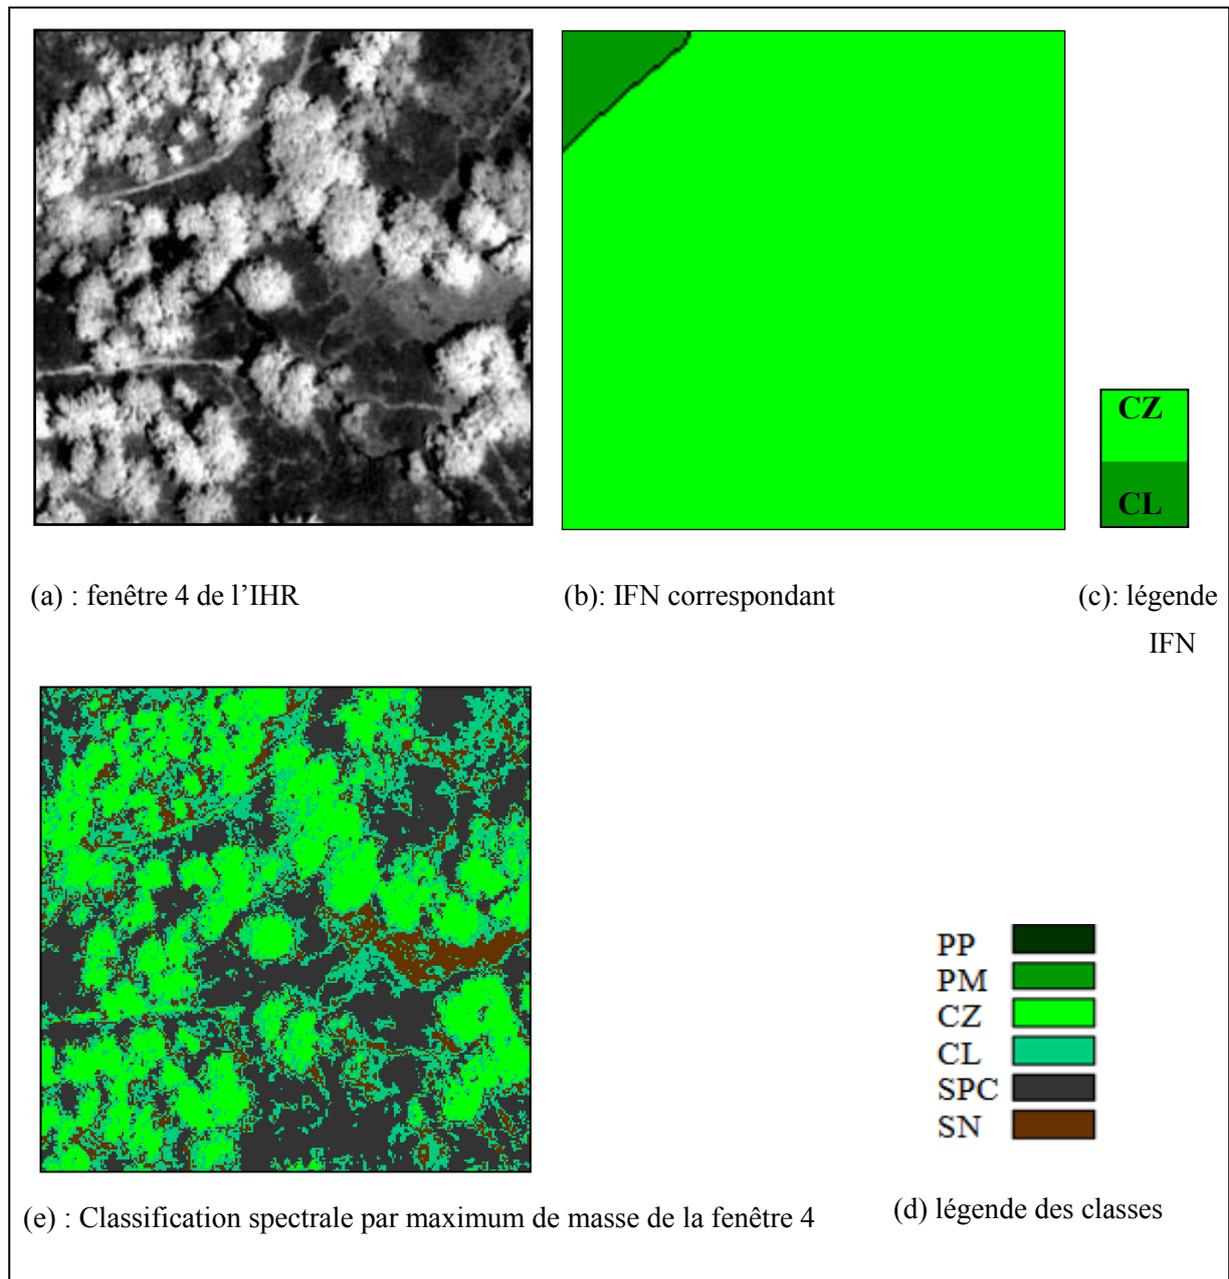


Figure VI.16. Classification spectrale par maximum de masse de la fenêtre 4 de l'IHR.

VI.5.1.2 Estimation à partir des histogrammes des exposants de Hölder

- Fenêtre 3 :

La figure VI.17 illustre le résultat de la classification sur la fenêtre 3 de l'IHR se basant de texture. La qualité des résultats est meilleure que celle de la classification spectrale (indice kappa égal à 0.7 et moyenne de la diagonale de la matrice de confusion égale à 75%).

La distinction entre les classes Pin pignon et Pin Maritime s'est beaucoup améliorée par rapport au résultat de la classification spectrale ce qui s'explique par la différence de texture entre ces deux classes qui sont mieux départagées par l'approche multi-fractale. Toutefois, la confusion reste importante entre les classes de pins, et significatives pour les classes de chênes comme le mentionne la matrice de confusion du tableau VI.5.

Classes estimées \ Classes réelles	PP	PM	CZ	CL	SPC	SN
PP	68.78	23	0	0	6.89	0.53
PM	24.44	49.04	0	4.73	2.46	18.33
CZ	0	0	92.86	7.14	0	0
CL	0	1.17	2.47	80.34	0	16.01
SPC	6.59	0	0	0	93.41	0
SN	0	5.99	0	26.13	0	67.88

Tableau VI.5. Matrice de confusion de la classification texturale par maximum de masse de la fenêtre 3 de l'IHR

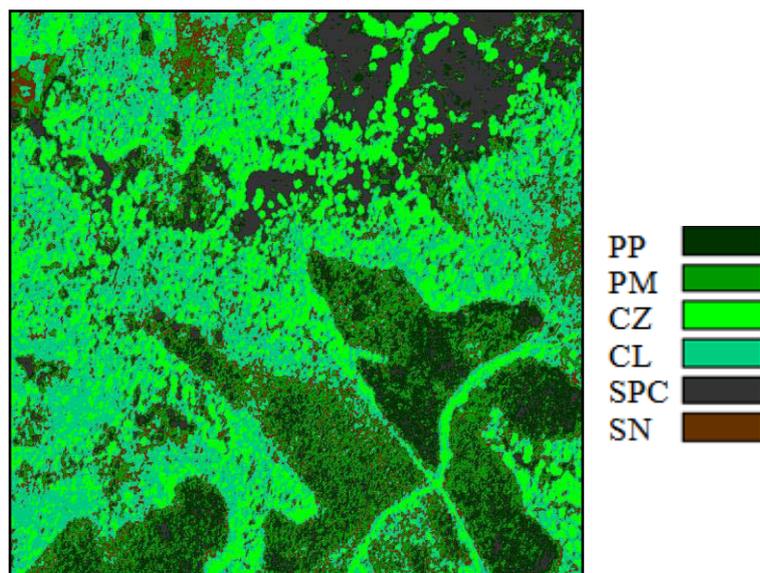


Figure VI.17. Classification texturale par maximum de masse de la fenêtre 3 de l'IHR.

- Fenêtre 4

La figure VI.18 illustre le résultat de la classification de l'image des exposants de Hölder de la fenêtre 4 de l'IHR en résolution réelle. La distinction entre les deux espèces chêne liège et chêne zen semble brouillée par une texture similaire qui caractérise ces deux classes.

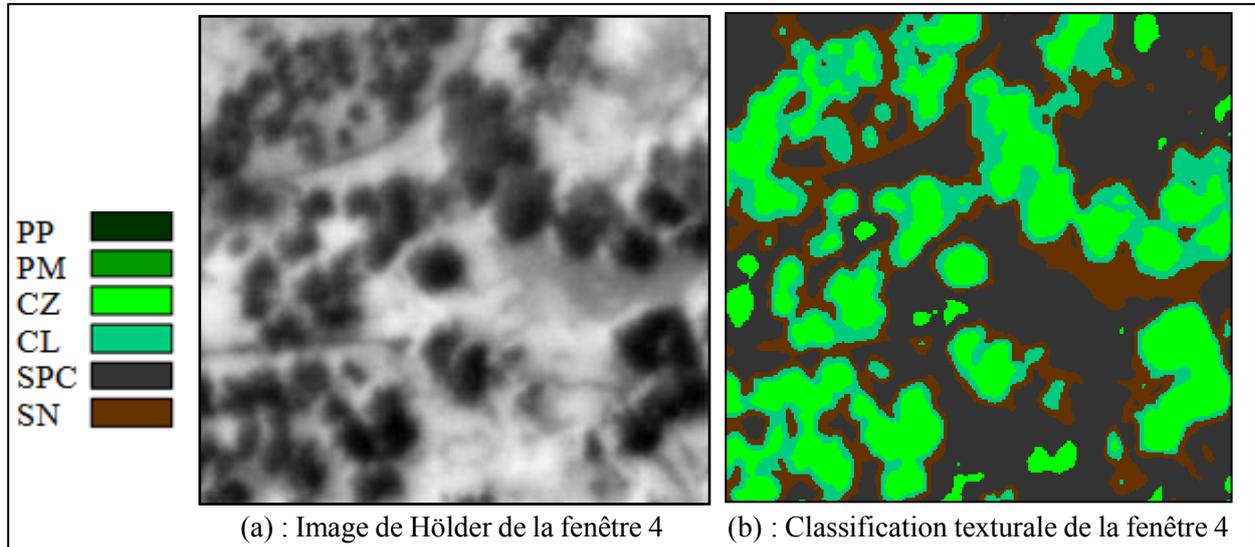


Figure VI.18. Classification texturale par maximum de masse de l'image de Hölder de la fenêtre 4 de l'IHR.

VI.5.2 Fusion des sources image et inventaire

La classification ponctuelle de la source image (fenêtre 1 de l'IHR de la figure VI.19) seule fournit une image assez « bruitée ». Ce bruitage est illustré tout d'abord sur les résultats des classifications par maximum de masses, de crédibilités, de plausibilités et de probabilité pignistique comme le montre la figure VI.20. Ensuite, nous présentons le tableau VI.6 illustrant l'évaluation numérique de la répartition d'affectations des échantillons correspondants à une vérité terrain (classes réelles) sur les différentes classes du cadre de discernement (avec une classification par maximum de masse (Tableau VI.6(a))) et sur les éléments focaux des référentiels de définition obtenus suite à une classification par maximum de crédibilité (Tableau VI.6(b)) et par maximum de plausibilités (Tableau VI.6(b)). Cette répartition montre que les décisions finales ne convergent pas vers des singletons mais plutôt vers des disjonctions de classes. Nous proposons de fusionner cette fenêtre 1 de notre image H.R et l'inventaire forestier correspondant (figure.VI.5(b)). Nous procédons tout d'abord par l'unification des deux cadres de discernement correspondant respectivement à la fenêtre 1 et à l'IFN qui lui est associé.

Unification des cadres de discernements

Soient $\Omega = \{C_1, C_2, C_3, C_4, C_5\}$ le cadre de discernement de la fenêtre image correspondant au choix des zones d'apprentissages décrit par la figure VI.19(b) et $\Omega' = \{C'_1, C'_2, C'_3, C'_4, C'_5, C'_6\}$ le cadre de discernement de l'inventaire correspondant. Selon les informations contenues dans

l'IFN, les classes de Ω' présentent ce qui suit : C'_1 = forêt de résineux, Pin Maritime (PM); C'_2 = Infrastructures (Infra); C'_3 = Arboretum (Arb) : Mélange feuillu et résineux. C'_4 = chêne Liège (CL); C'_5 = chêne zen (CZ); C'_6 = CL+CZ. Selon la localisation des échantillons des zones d'apprentissage choisies, nous déduisons les correspondances suivantes $C'_1 = C_2 \cup C_3$; $C'_2 = C_5$; $C'_3 = C_2 \cup C_3 \cup C_4$; $C'_4 = C_2 \cup C_4$; $C'_5 = C_1$; $C'_6 = C_1 \cup C_4$.

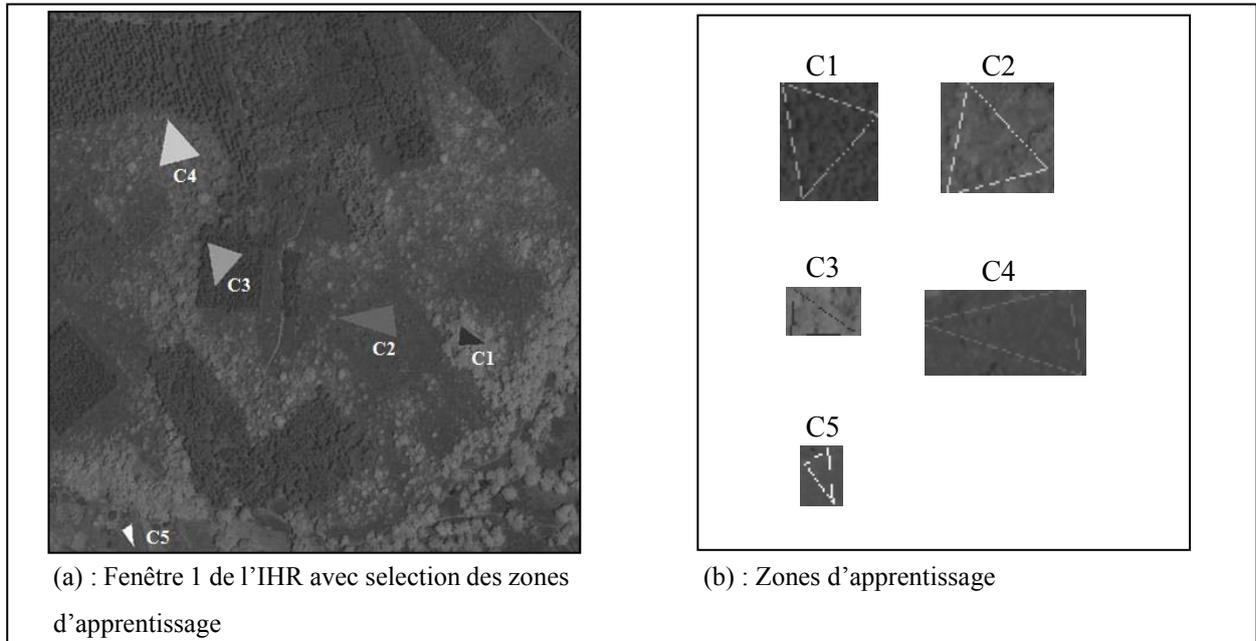
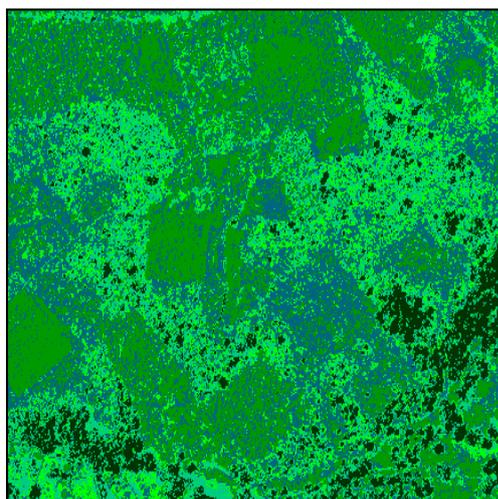


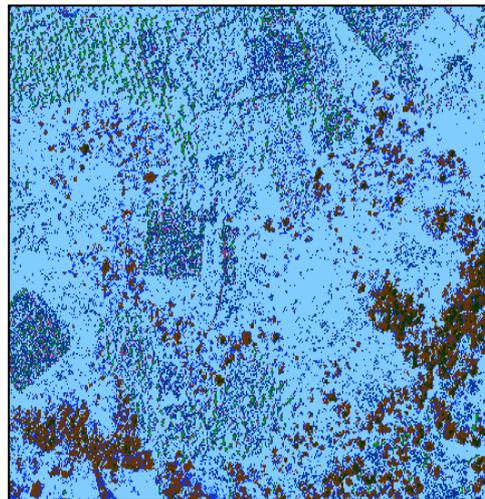
Figure VI.19. Choix des zones d'apprentissages sur la fenêtre 1 de l'IHR.

Si nous faisons le raisonnement inverse en associant aux zones d'apprentissages les types de l'inventaire forestier national dont nous disposons pour la fenêtre 1, nous obtenons les correspondances suivantes :

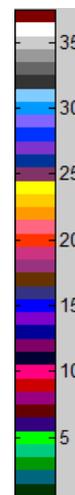
$C_1 \rightarrow C'_5 : C.Z$; $C_2 \rightarrow C'_3$: Mélange de feuillus et résineux ; $C_3 \rightarrow C'_3$: Mélange de feuillus et résineux ; $C_4 \rightarrow C'_6 : C.Z + C.L$; $C_5 \rightarrow C'_2$: infrastructures.



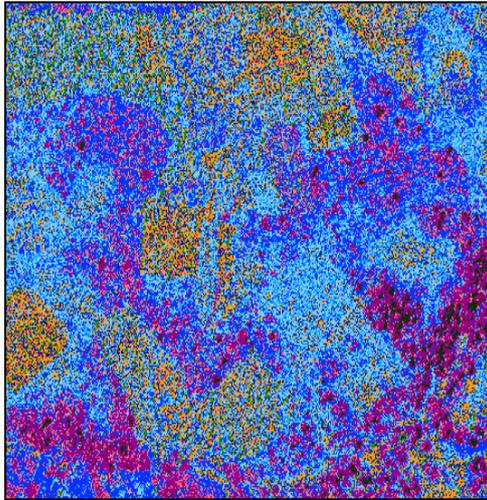
(a) : Fenêtre 1 de l'IHR



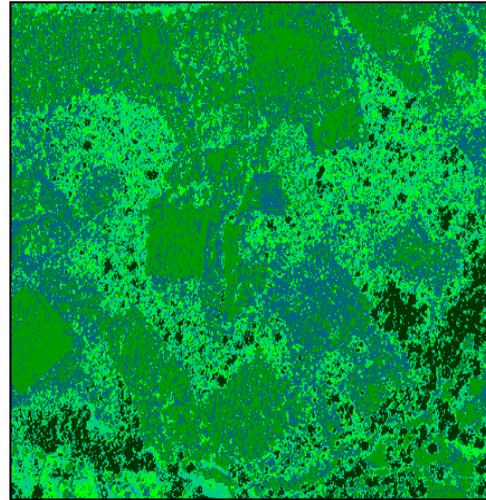
(b) : Classification par maximum de masses



(c) : légende des événements



(c) : Classification par maximum de plausibilités



(d) : Classification par maximum de probabilités pignistique

Figure VI.20. Classification de la fenêtre 1 de l'IHR par maximum de masses, de crédibilités, de plausibilités et de probabilités pignistique.

Les chevauchements de la classe C_2 avec les autres classes (illustré par les figures IV.1 jusqu'à IV.6) sont bien expliqués par l'inventaire correspondant (cette classe représente un mélange de feuillis et résineux). D'autre part, la classe C_5 est un mélange entre les espèces chêne liège et chêne zen.

Classes estimées / Classes réelles	C1	C2	C3	C4	C5
C1	86.13	1	0.44	10.54	1.89
C2	0	80.91	8.18	0.75	10.17
C3	0	9.80	90.20	0	0
C4	9.73	7.55	1.93	58.32	22.48
C5	0.50	5.26	0	35.34	58.90

(a) : Matrice de confusion de la classification par maximum de masses

Elements de F / Classes réelles	A1	A2	A3	A4	A5	A6	A7	A8
C1	25.86	0	0	60.49	0	0	7.10	6.55
C2	0	0	0.12	0	0	1.71	0	98.17
C3	0	12.82	6.59	0	9.76	42.19	0	28.65
C4	0	0	0	15.06	0.10	0.87	21.03	62.94
C5	0	0	0	0	0	0	8.52	91.48

(b) : Répartition des affectations sur les éléments focaux obtenus suite à la classification par maximum de crédibilités

Elements de F' Classes réelles	A'1	A'2	A'3	A'4	A'5	A'6	A'7	A'8	A'9	A'10
C1	25.86	0	60.49	0	0	7.10	0	5.11	0	1.00
C2	0	0	0	0.12	0	0	1.71	10.91	33.12	47.79
C3	0	12.82	0	6.59	9.76	0	42.19	0	2.89	6.91
C4	0	0	15.06	0	0.10	21.03	0.87	54.43	2.57	4.98
C5	0	0	0	0	0	8.52	0	86.22	1.00	4.26

(c) : Répartition des affectations sur les éléments focaux obtenus suite à la classification par maximum de plausibilités

Tableau VI.6. Matrice de confusion de la classification par maximum de masses et matrices de répartition des affectations des échantillons sur les éléments focaux obtenus suite à la classification par maximum de crédibilités et par maximum de plausibilités.

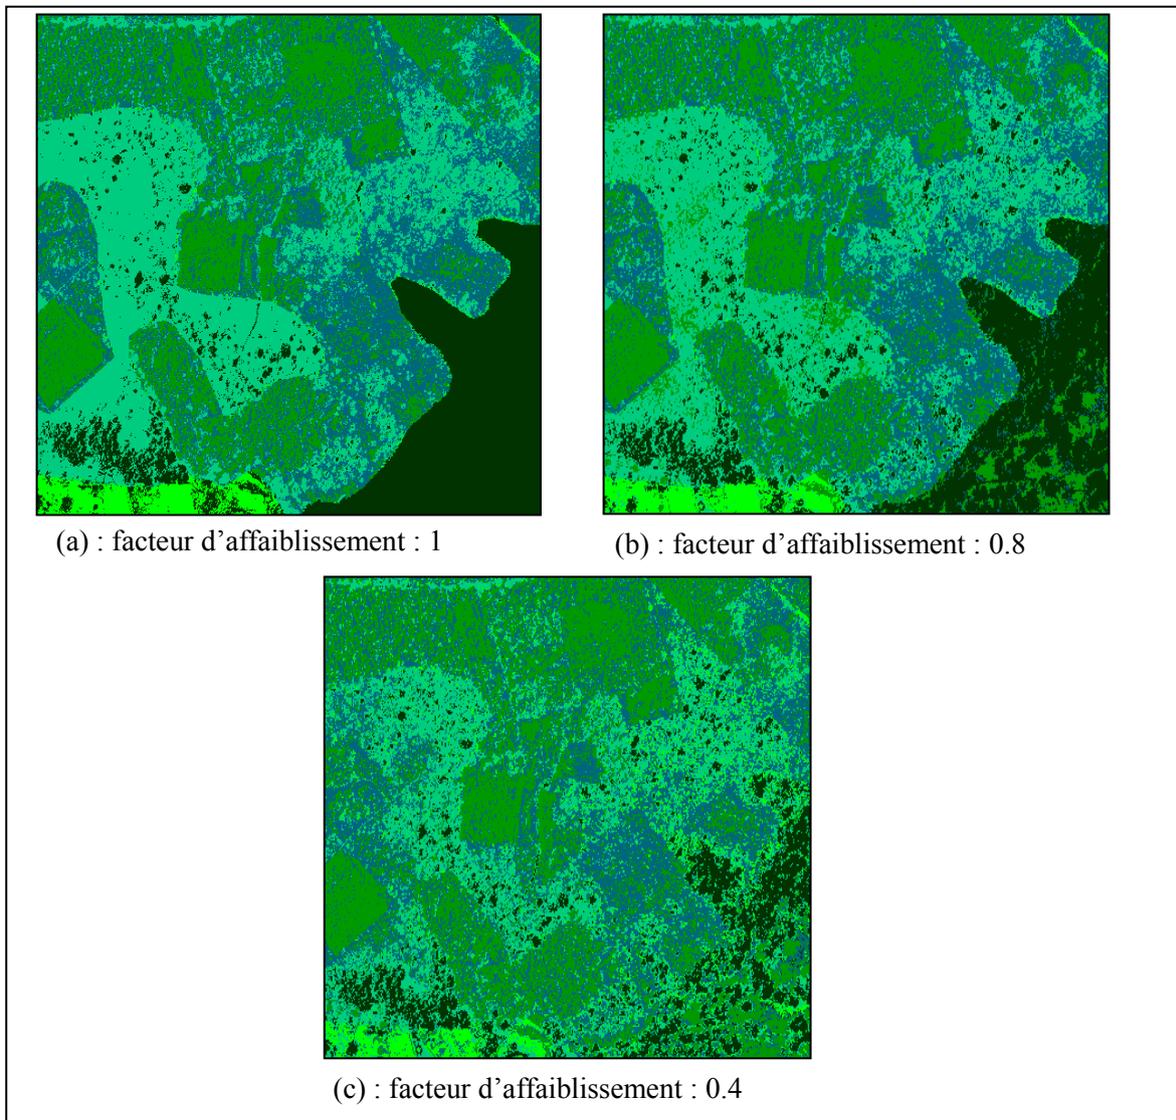


Figure VI.21. Classification par fusion de l'image et de l'inventaire par maximum de masses avec différents facteurs d'affaiblissement de l'inventaire.

Les événements qui apparaissent dans la classification par maximum de crédibilité sont :

$$A_1 = C_1 ; A_2 = C_3 ; A_3 = C_1 \cup C_2 \cup C_3 ; A_4 = C_1 \cup C_2 \cup C_4 ; A_5 = C_1 \cup C_3 \cup C_4 ; \\ A_6 = C_1 \cup C_2 \cup C_3 \cup C_4 ; A_7 = C_1 \cup C_2 \cup C_4 \cup C_5 ; A_8 = C_1 \cup C_2 \cup C_3 \cup C_4 \cup C_5 .$$

Ceux dans la classification par maximum de plausibilité sont :

$$A'_1 = C_1 ; A'_2 = C_3 ; A'_3 = C_1 \cup C_4 ; A'_4 = C_2 \cup C_3 ; A'_5 = C_3 \cup C_4 ; A'_6 = C_1 \cup C_4 \cup C_5 ; \\ A'_7 = C_2 \cup C_3 \cup C_4 ; A'_8 = C_1 \cup C_2 \cup C_3 \cup C_4 ; A'_9 = C_2 \cup C_3 \cup C_4 \cup C_5 ; \\ A'_{10} = C_1 \cup C_2 \cup C_3 \cup C_4 \cup C_5 .$$

La classification ponctuelle proposée dans cette sous-section et appliquée sur la fenêtre 1 donne des résultats assez satisfaisants. Cependant, par simple interprétation visuelle et en superposant l'image initiale et sa classification, nous remarquons que certains pixels d'un même arbre ont été classés dans deux classes ou plus, et qu'en fusionnant les sources image et inventaire et en affaiblissant la source inventaire, nous remarquons que certains groupements d'arbres d'espèces différentes cohabitant ensemble ont été classés dans la même classe. Ceci est essentiellement dû à l'aspect grossier de l'inventaire forestier.

Pour faire face à ce problème, nous proposons d'appliquer un algorithme d'extraction des couronnes d'arbres. En effet, l'application d'un tel algorithme sur l'image permettra de localiser les couronnes d'arbres et d'éviter le premier type de problème (associer les pixels d'un même arbre à plus qu'une classe). Il s'agit d'affecter chaque couronne à une classe. Nous nous basons pour cela sur le résultat de la classification ponctuelle pour décider. Ainsi, il s'agit d'interdire aux pixels du même arbre d'appartenir à des classes différentes. Nous associons alors tous les pixels contenus dans la même couronne d'un arbre à la classe à laquelle la majorité des points de la couronne ont été affectés. Ainsi, nous pouvons considérer le résultat de l'algorithme de croissance de régions par mouvement brownien comme une nouvelle source d'information. Les résultats de cette approche sont détaillés dans la sous-section suivante.

VI.5.3 Fusion contextuelle

Nous exposons dans ce qui suit les résultats de l'application de notre approche de fusion contextuelle sur des fenêtres de notre image QuickBird. Pour les espèces forestières, nous avons choisi d'illustrer l'importance de la source image des couronnes dans l'amélioration de la qualité de la classification. Pour les classes de pin maritimes et pin pignon, nous avons utilisé l'inventaire numérisé en tant que source d'informations contextuelle pour la révision des masses.

VI.5.3.1 Révision par la source déduite « Image des couronnes »

L'algorithme d'extraction des couronnes par mouvement Brownien a été appliqué pour segmenter les fenêtres d'images en couronnes, ce qui permettra de chercher des masses contextuelles à travers un transfert de croyance. Comme nous l'avons déjà détaillé au chapitre V, le transfert de croyance consiste à recalculer une distribution de masses afin d'obtenir une

nouvelle distribution prenant en considération l'arrivée d'une information considérée comme certaine (issue d'une source fiable) et se traduit donc par une révision par une nouvelle information. Cette nouvelle information est pour notre cas une information contextuelle. Il s'agit donc de redistribuer les masses initialement issues d'une source et estimées sur l'ensemble des éléments focaux composés vers les sous-ensembles ne se contredisant pas avec le contexte considéré, ce qui augmente la masse des événements inclus dans le contexte et annule la masse des événements considérés comme impossibles selon ce même contexte (c.à.d. les événements qui doivent avoir des masses non nulles pour le(s) contexte(s) contraire(s)).

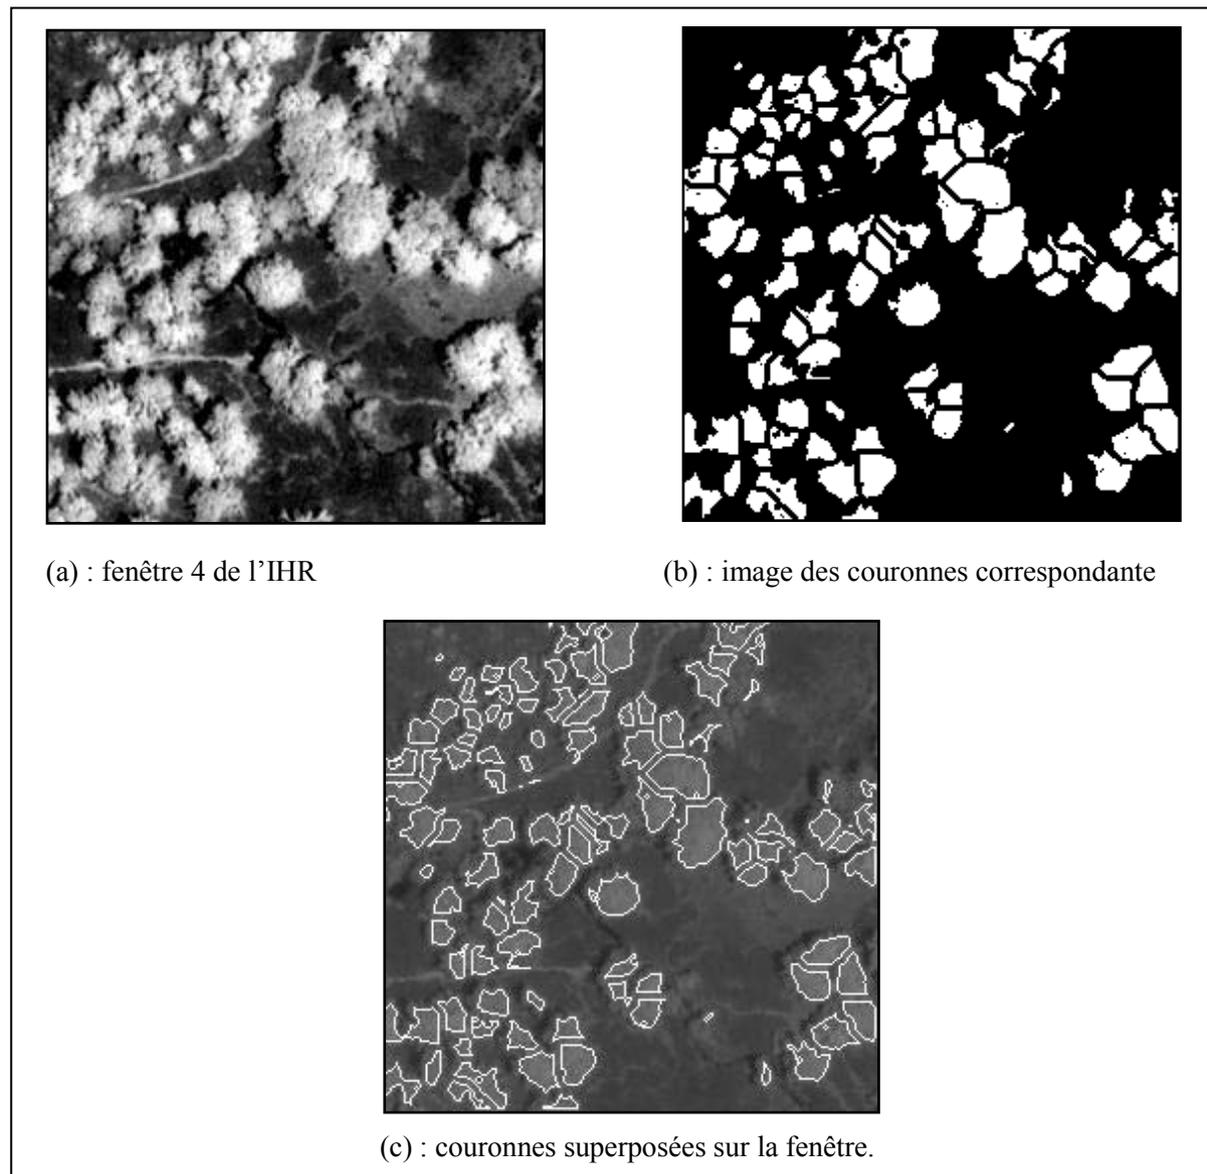


Figure VI.22. *Extraction des couronnes de la fenêtre 4 de l'IHR par ECBM.*

Le résultat de l'application de l'algorithme d'extraction des couronnes par mouvement Brownien sur la fenêtre de la figure VI.22 (a) est illustré par les figures VI.22 (b) et (c). En se basant sur l'image des couronnes, nous appliquons un transfert de croyances basé sur l'information contextuelle qui se traduit ici pour chaque pixel de l'image par son appartenance (ou non appartenance) à l'intérieur (ou à l'extérieur) d'une couronne. Ceci permettra de réduire considérablement la présence de pixels appartenant à des espèces forestières à l'extérieur des couronnes (réduire la présence de chêne zen et de chêne liège à l'extérieur d'une couronne) et d'effectuer donc un transfert de masses vers les classes d'occupation non forestières (sol nu et sol peu couvert). Le découpage des groupements d'arbres permet à la fois de fixer les contextes et d'appliquer une classification à l'arbre près. Sachant que la classification est basée sur une approche ponctuelle, nous constatons dans une même couronne des classes d'occupation forestières différentes (chêne liège et chêne zen).

VI.5.3.2 Exploitation de l'information structurelle pour la fusion

L'image des couronnes a été utilisée pour définir des contextes et transférer des masses de croyance. Toutefois, les couronnes apportent une information souvent pertinente pour l'identification de la nature d'une espèce forestière. La structure de la couronne est en effet une donnée capable de départager quelques espèces forestières. Dans le chapitre V, nous avons introduit quelques définitions pour l'information structurelle et les indices de formes. La fusion de sources d'informations guidée par l'intégration de l'information structurelle révèle une meilleure séparation entre les deux classes chêne zen et chêne liège. Ceci justifie la rigueur du choix de l'intégration de l'information structurelle (ici mesure : aire des couronnes) dans la distinction entre ces deux classes. La figure VI.23 (a) illustre le résultat de la classification de la fenêtre de la figure VI.22(a) avec un transfert appliqué sur la distribution de masses estimé à partir des exposants de Hölder. Cette figure illustre la distinction entre les classes chêne zen et chêne liège et converge vers un résultat de classification très proche de la réalité.

	Cz	Cl
Nombre de couronnes	57	43
Couronnes mal classées	3	5
Couronnes bien classées	54	38
Pourcentage de couronnes bien classées	94%	88%

Tableau VI.7. Evaluation de la classification des couronnes de la fenêtre 4.

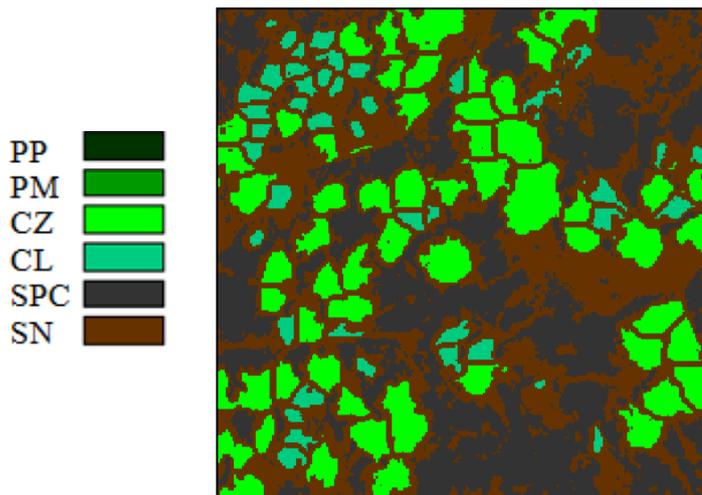
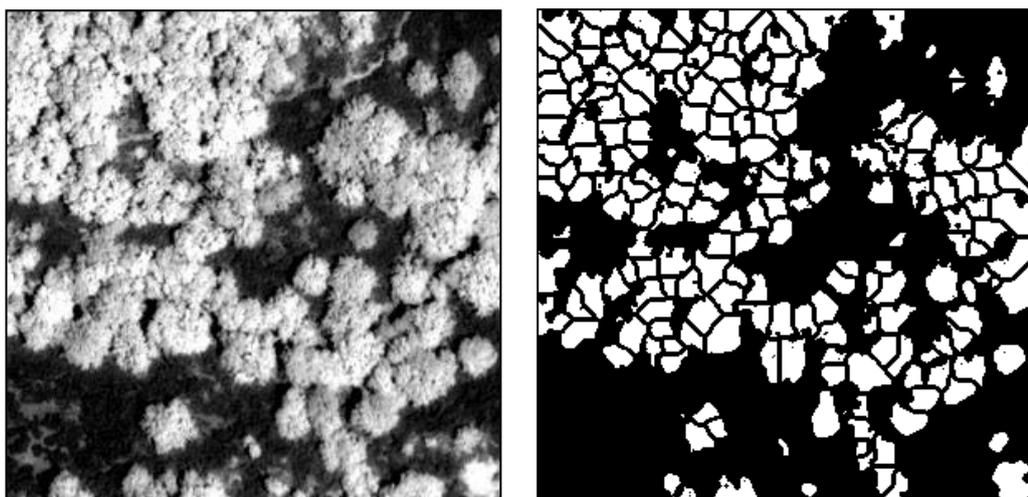


Figure VI. 23. Résultat de la classification par maximum de masse de la fenêtre 4 de l'IHR après révision de la distribution de masse texturale par l'information couronne et fusion avec l'information structurelle.

Pour l'évaluation de l'apport de notre approche dans le résultat final nous avons choisi de distinguer les deux catégories de classes dans la fenêtre HR, à savoir les classes d'arbres (chêne liège et chêne zen) et les classes de sol peu couvert et sol nu. La séparation entre ces deux catégories de classes s'avère totale au niveau du résultat final. Au sein d'une même catégorie, la séparation entre classes varie. La distinction entre les deux classes C5 et C6 est totale, mais une faible confusion demeure entre les deux classes C1 et C2. Sur les 100 couronnes dégagées par l'algorithme d'extraction par mouvement Brownien, 43 ont été classées en C4 (CL) et 57 en C3 (CZ). L'interprétation de ces résultats par un expert du terrain aboutit à l'évaluation énumérée dans le tableau VI.7



(a) : Fenêtre 5 de l'IHR

(b) : Image des couronnes correspondante

Figure VI.24. Extraction des couronnes de la fenêtre 5 de l'IHR par ECBM.

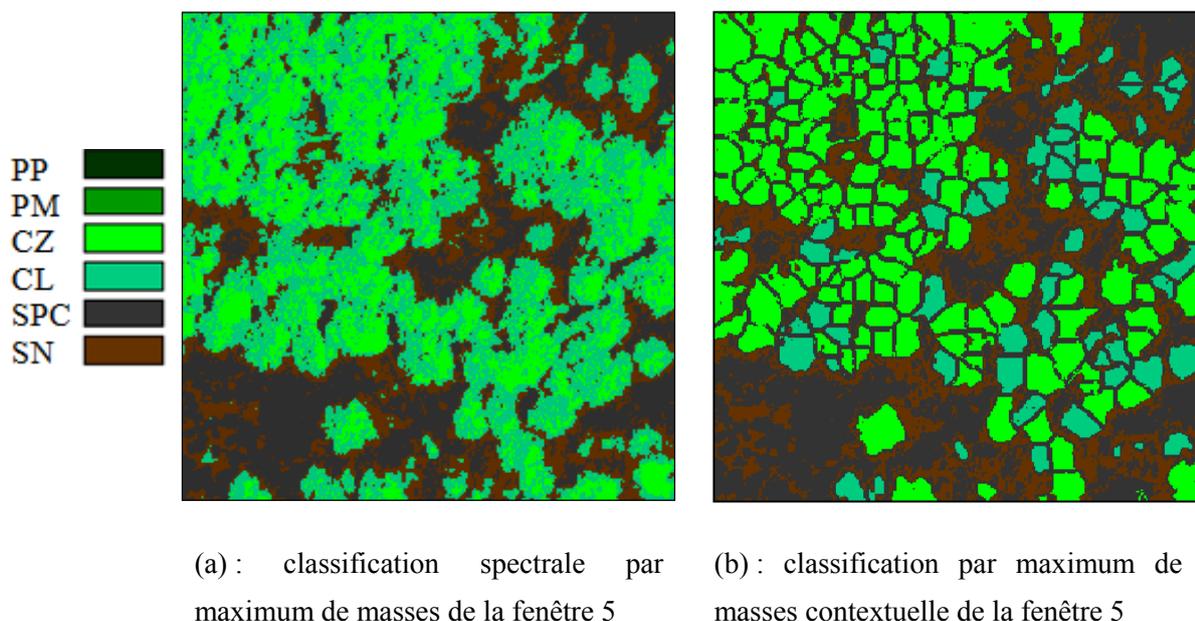


Figure VI.25. *Exploitation de l'information contextuelle : application sur la fenêtre 5 de l'IHR*

La figure VI.24 présente une autre fenêtre extraite à partir de l'IHR (fenêtre 5) et sur laquelle nous avons appliqué notre approche de classification. Ce qui a donné les résultats illustrés par la figure VI.25. Le tableau VI.8 apporte une évaluation numérique des résultats dégagés. Cette deuxième fenêtre confirme les déductions que nous venons d'apporter de l'application de notre démarche. Un taux moyen de 90% dans les zones où l'inventaire numérisé confond les deux classes CL et CZ est considéré comme un résultat très satisfaisant.

	Cz	Cl
Nombre de couronnes	151	64
Couronnes mal classées	6	9
Couronnes bien classées	145	55
Pourcentage de couronnes bien classées	96%	86%

Tableau VI.8. *Evaluation de la classification des couronnes de la fenêtre 2.*

VI.5.3.3 Révision par l'inventaire

La figure VI.26 illustre le résultat de l'exploitation de l'information contextuelle à travers une révision par l'inventaire numérisé, appliquée sur une autre fenêtre de notre IHR (fenêtre 6 représentée par la figure VI.26(a)). Les espèces de la zone d'apprentissage sont essentiellement les deux classes de pin pignon et le pin maritime (inventaire de la figure VI.26(c)). La classification texturale sur la base de la distribution de masses issues des exposants de singularités montre une homogénéité au niveau de la classe pin pignon et beaucoup de confusion au niveau de la classe de pin maritime comme le montre la figure VI.26(b). L'intégration de l'inventaire en tant que source fiable pour le transfert de croyances offre

comme résultat une classification qui ressemble beaucoup à la décomposition en polygones de l'inventaire. Ceci est illustré par le résultat de la figure VI.26(d) où la décomposition des classes est très proche de celle de l'inventaire forestier.

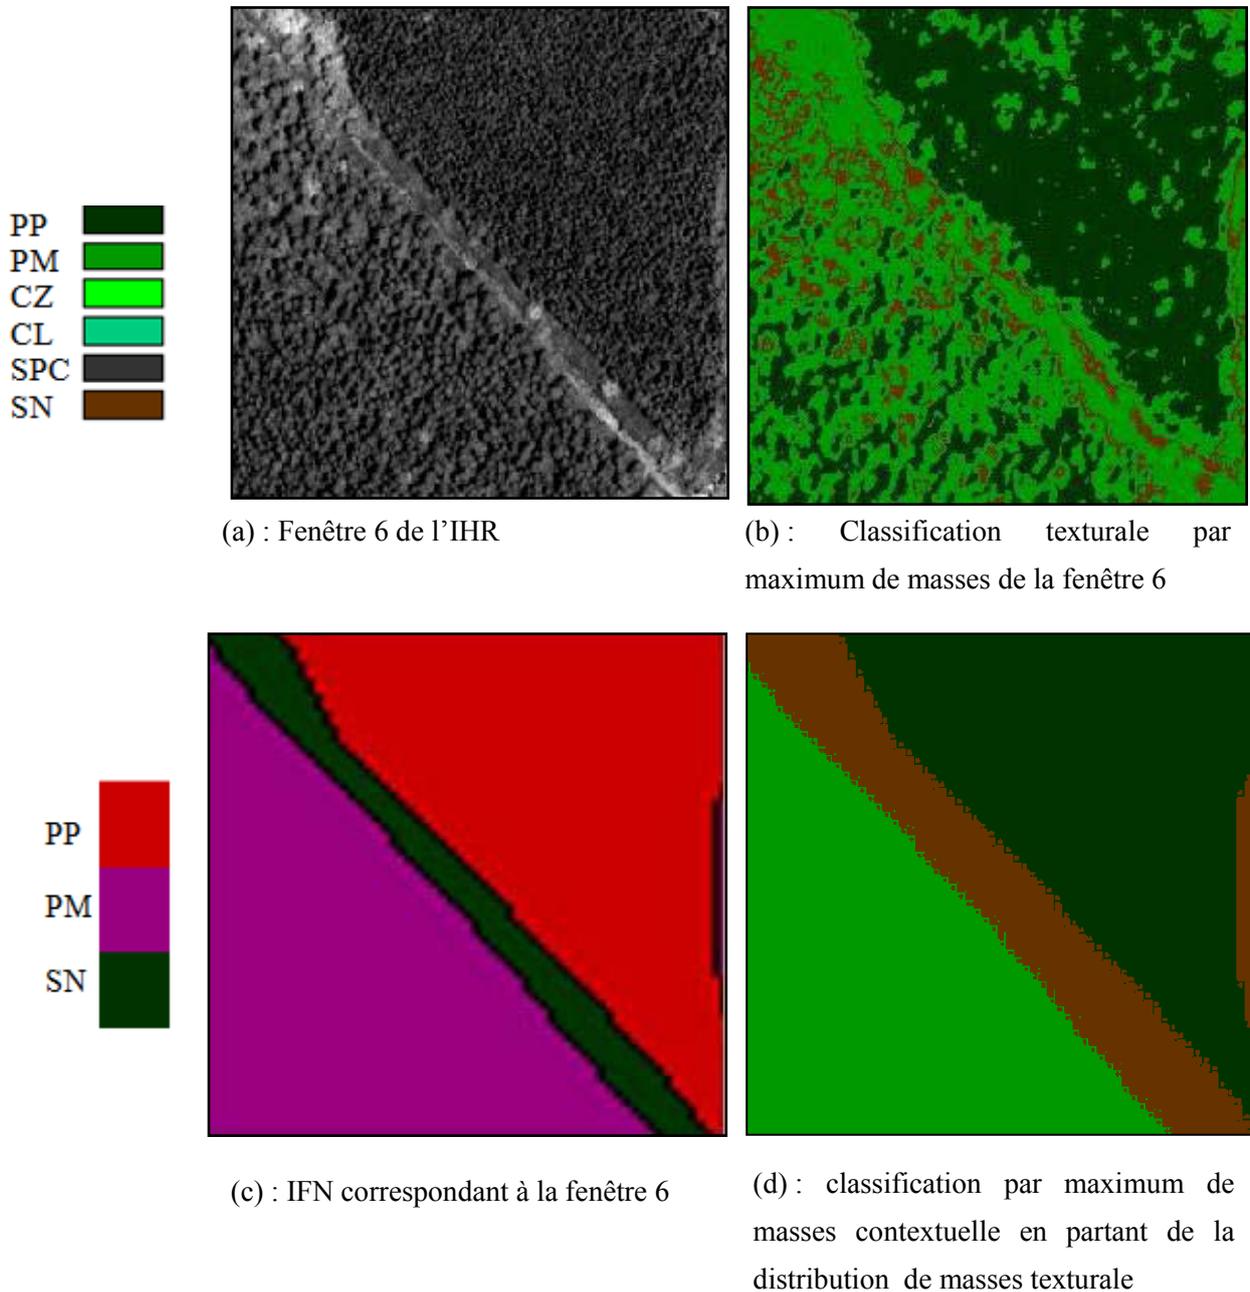


Figure VI.26. Exploitation de l'information contextuelle issue de l'IFN : application sur la fenêtre 6 de l'IHR.

VI.6 Evaluation globale du système de fusion

Dans les sections précédentes, nous avons présenté les résultats de l'application des différentes étapes du processus de fusion. Nous présentons ici une évaluation globale de notre système de fusion (on le désignera dans ce qui suit par M1) par rapport à des méthodes classiques de fusion basées sur le formalisme probabiliste et évidentiel en variant les sources d'informations. L'objectif étant d'illustrer l'apport des sources déduites et le traitement contextuel impliqué dans notre système de fusion.

L'expérimentation a été basée sur les sources suivantes :

S1 : fenêtre 2000*2000 de l'image QuickBird (figure VI.8.a)

S2 : l'image de Hölder correspondante à S1 (figure VI.9.a)

S3 : l'image des couronnes d'arbre issue de S1 (Source déduite)

S4 : L'inventaire numérisé correspondant à la scène (Figure VI.8.b)

La comparaison de notre système de fusion est alors évaluée par rapport aux méthodes suivantes :

- M2 : fusion basée sur le formalisme des fonctions de croyances non contextuelle (S1+S2) :

Il s'agit de fusionner les distributions de masses de S1 et de S2, déterminées à partir des histogrammes de niveaux de gris et des exposants de singularités respectivement, par l'opérateur orthogonal de Dempster (distributions de masses mono-source déterminées comme détaillée dans le chapitre V)

- M3 : fusion basée sur le formalisme probabiliste. (S1+S2)

Il s'agit d'effectuer une fusion Bayésienne des distributions de probabilités de S1 et S2 déterminées à partir des histogrammes de niveaux de gris et des exposants de singularités.

- M4 : fusion basée sur le formalisme probabiliste (S1+S4)

Il s'agit d'effectuer une fusion Bayésienne des distributions de probabilités de S1 et de S2 déterminées à partir des histogrammes de niveaux de gris et de l'IFN respectivement. Nous associons à tous les points d'un même polygone de l'inventaire une même probabilité en faisant la correspondance avec les classes du cadre de discernement.

- M5: fusion basée sur le formalisme probabiliste (S1+S4) en se basant sur l'information experte de cohabitation des classes :

A la différence de la méthode M4, nous implémentons la méthode M5 pour prendre en compte les règles expertes concernant la cohabitation entre classes (par exemple si le polygone de l'inventaire indique le type chêne liège, on associe une probabilité non nulle à CL et à CZ

aussi du fait que nous disposons d'une règle experte indiquant la cohabitation des espèces CL et CZ).

Les zones d'apprentissages ont été définies pour huit classes recensées dans la scène correspondante aux sources d'informations impliquées. Ces classes correspondent aux occupations suivantes : {chêne liège (CL), chêne zen (CZ), cyprès, pin pignon (PP), pin maritime (PM), sol nu, zone agro-forestière, routes} qui composent notre cadre de discernement.

VI.6.1 Interprétation numérique

L'évaluation numérique est introduite par :

- La figure VI.27 qui trace la courbe du pourcentage de bonne classification relativement aux différentes méthodes.
- La figure VI.28 (a) qui trace les facteurs Kappa pour les différentes méthodes
- La figure VI.28 (b) qui trace les valeurs de l'exactitude globale
- La figure VI.29 (a) qui trace la courbe des erreurs d'omission
- La figure VI.29 (b) qui trace les courbes des erreurs de commission

VI.6.1.1 Analyse de la diagonale de la matrice de confusion

L'analyse de la diagonale de la matrice de confusion dégagée par l'application des 5 méthodes apporte plus de détails sur les résultats.

Classe chêne liège : le meilleur pourcentage est attribué à M4 (100%) et M5 (95%). Ces deux méthodes issues du formalisme probabiliste dégagent un meilleur résultat pour CL à travers le recours à la source S4 dont l'implication dans le système de fusion, pour la classe CL, améliore le résultat dégagé avec les seules sources S1 et S2. En effet, pour la zone d'apprentissage associée à CL, la valeur du polygone correspondant dans l'inventaire (S4) indique cette même classe. La source S4 influe beaucoup le résultat avec une fusion probabiliste. Cependant, notre méthode M1, procède par révision par S4, le résultat correspondant est justifiable puisque les pixels de la zone d'apprentissage correspondant à CL ont été repartis entre CL avec 90% et CZ avec 10%. Ce qui peut être considéré comme un bon résultat vu la cohabitation de ces deux espèces.

Classe chêne zen : Le meilleur résultat est attribué à M1 (90%) avec un taux largement supérieur à celui obtenu à partir des autres méthodes. Ceci s'explique par la richesse de l'information contextuelle apportée par les couronnes d'arbre et utilisée dans M1 ainsi que l'apport de la redistribution des masses des unions de classes appliquées.

Ainsi, pour les deux classes Chêne liège et Chêne zen nous obtenons, en moyenne, un meilleur résultat à travers notre système de fusion.

Classe Cyprès : Un score de 96% est obtenu par M1 (avec environ 4% associé à la classe CZ) et un score de 100% par M4 vu l'influence de la fusion probabiliste avec l'inventaire pour cette dernière méthode. La comparaison des pourcentages de bonne classification dégagée par M4 et M2 (75%) explique l'apport de la source S4 dans l'amélioration du résultat.

Classe Pin Pignon : Le meilleur résultat est obtenu par M4 (100%). Ce taux s'explique par l'effet de la fonction de probabilité estimée pour la source S4 relativement à la classe pin pignon. Si M4 arrive à dégager un pourcentage élevé pour cette classe, le pourcentage qu'elle dégage pour la classe pin maritime est nul. D'où la confusion totale entre ces deux classes fournie par M4.

Classe Pin Maritime : Le meilleur résultat est obtenu par M1 (66%). Les autres méthodes donnent un résultat nettement inférieur.

Aussi, la moyenne des deux classes Pin Pignon et Pin Maritime revient à M1 qui réussit à lever une grande part de confusion émanant de l'information spectrale.

Classe sol nu : Toutes les méthodes fournissent un taux de 100% pour cette classe dont l'information spectrale est déterminante et assure une séparabilité totale avec les autres classes.

Classe agro forestière : Le meilleur résultat étant obtenu pour cette classe par M1, M4 et M5 (100%). L'effet de la source S4 se manifeste par ce taux élevé. Toutefois, la source S2 est à l'origine de confusion avec la classe Cyprès, ce qui explique les taux inférieurs pour les méthodes M2 et M3. Cet effet est évité par la redistribution des masses par l'information contextuelle effectuée par notre méthode M1.

Classe route : Le meilleur résultat est obtenu par M1 (98%), les autres méthodes fournissent des résultats assez proches.

VI.6.1.2 Analyse du facteur Kappa

L'analyse du facteur Kappa de la classification relativement aux différentes méthodes (figure VI.28(a)) appliquées informe sur un facteur maximum attribué à M1 (0.72) ce qui place le résultat obtenu avec l'application de notre système de fusion au dessus de ceux obtenus avec les autres méthodes. Le résultat obtenu avec les méthodes basées sur le formalisme probabiliste (M3, M4 et M5) révèle un facteur compris entre 0.33 et 0.53 et indique la difficulté d'une démarche classique pour départager des classes d'occupation caractérisées par une confusion spectrale et s'appuyant sur des sources d'information du domaine forestier. Le résultat se référant à M3 est assez proche de celui de M2 ce qui explique l'importance des sources S3 et S4 et l'apport de l'approche de fusion adoptée par M1.

VI.6.1.3 Analyse de l'exactitude globale

La figure VI.28(b) illustre l'exactitude globale de la classification pour l'ensemble des 5 méthodes expérimentées. Nous obtenons avec notre système (M1) une exactitude globale de

79% supérieure à celles fournies par les autres méthodes dont l'exactitude globale varie entre 0,42 et 0,62.

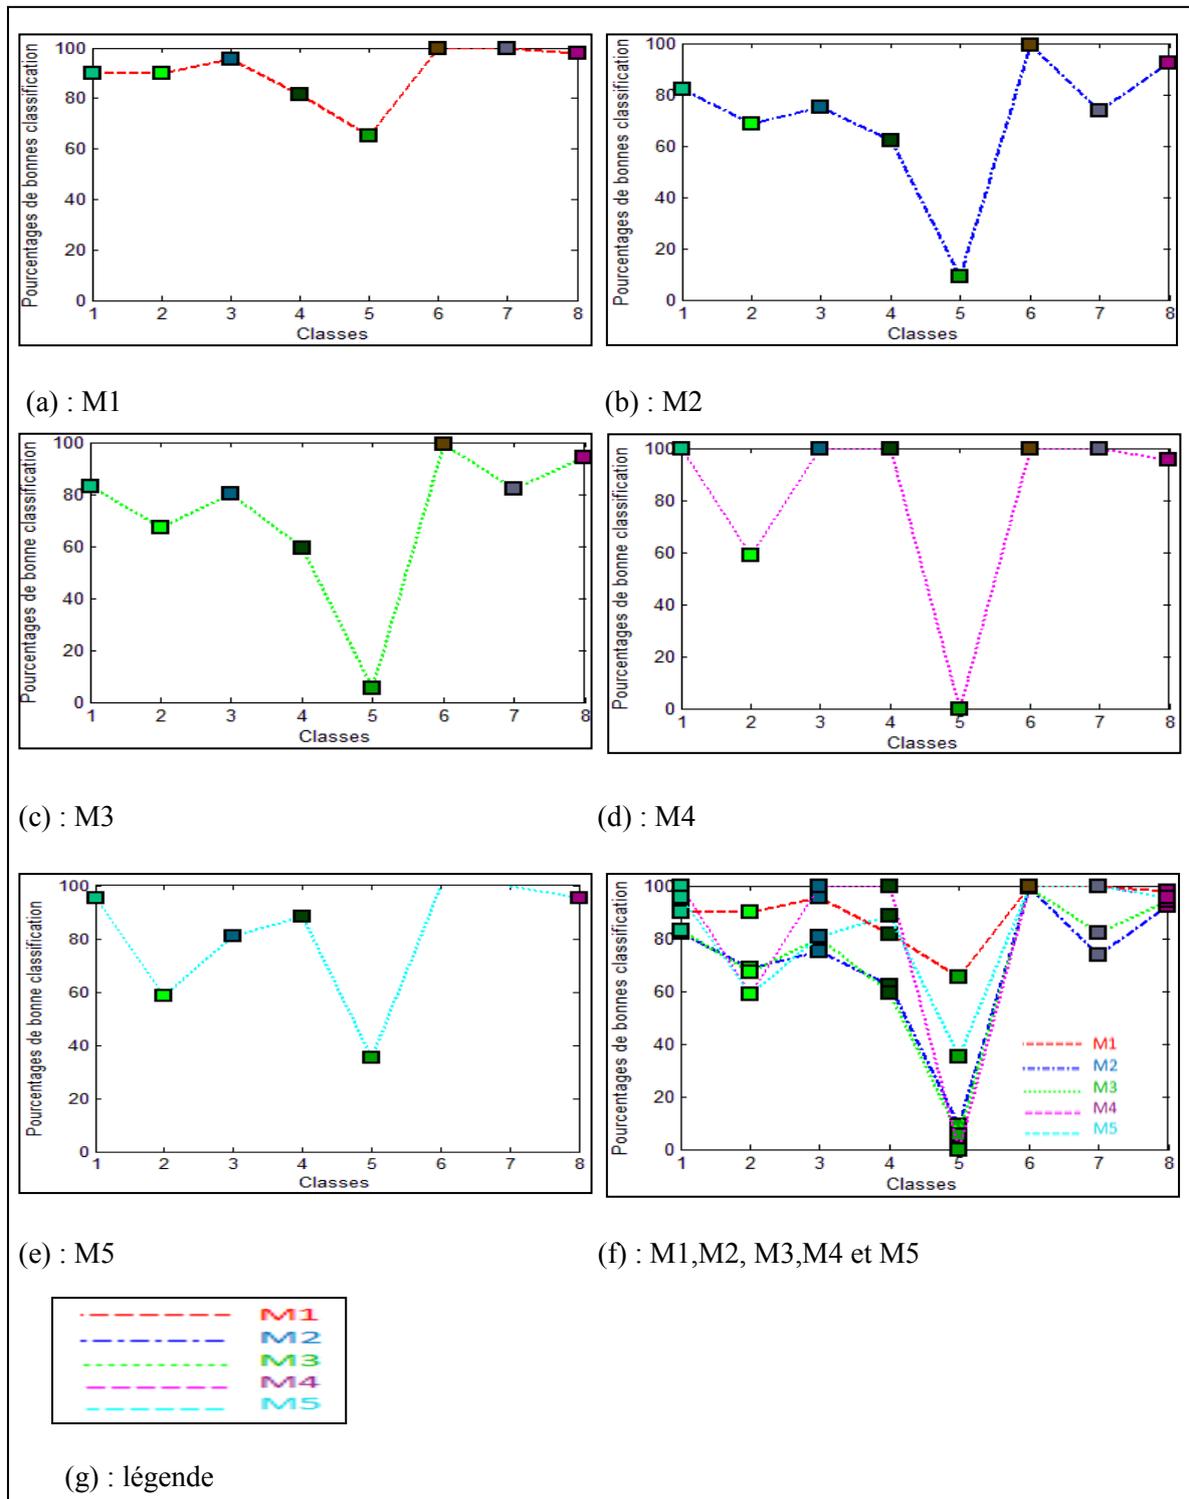
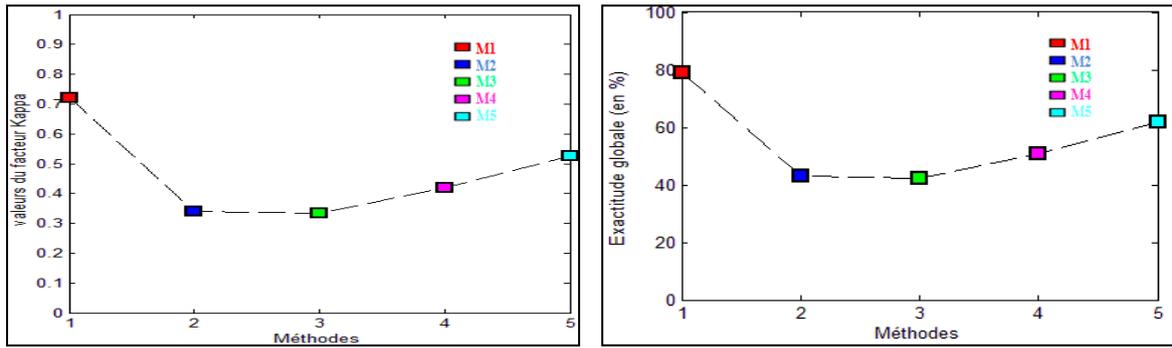


Figure VI.27. Pourcentages de bonnes classifications par les cinq méthodes séparées (a)-(e) et (f) superposées.



(a) : valeurs du facteur Kappa

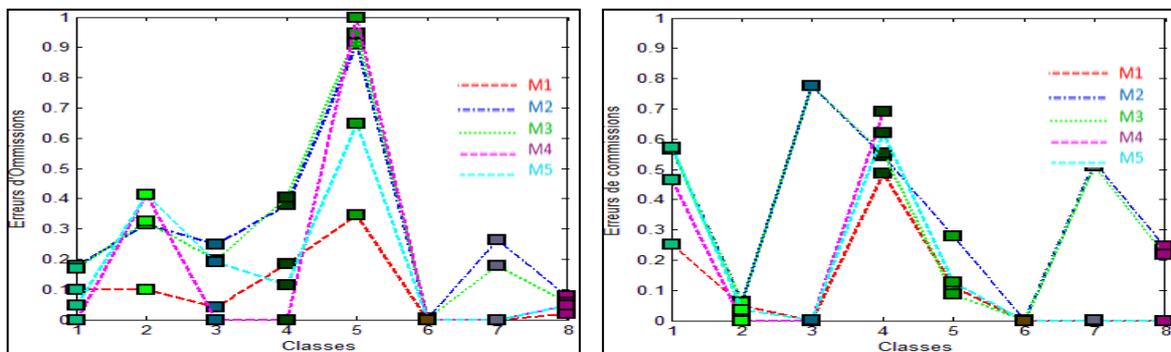
(b) : valeurs de l'exactitude globale

Figure VI.28. Valeurs du facteur kappa pour les cinq méthodes

VI.6.1.4 Analyse des erreurs d'omissions et de commissions

La figure VI.29.(a) illustre la courbe des erreurs d'omission (pixels incorrectement exclus de la classe) relativement aux méthodes appliquées. La comparaison de la somme des erreurs d'omission des différentes méthodes révèle une erreur minimale pour notre système (0,79 pour M1; 2,38 pour M2; 2,28 pour M3; 1,59 pour M4 et 1,46 pour M5).

La figure VI.29 (b) illustre les erreurs de commission dégagées par les différentes méthodes (Pixels assignés incorrectement à une classe et qui appartient en fait à une autre classe). Encore ici, ces erreurs sont minimales pour notre système.



(a) : erreurs d'omissions

(b) : erreurs de commissions

Figure VI.29. Courbes des erreurs d'omission et de commission pour les huit classes selon les cinq méthodes.

Les erreurs d'omission et de commission les plus importantes atteignent leurs niveaux maximum pour les deux classes Chêne Zen et Pin Pignon (pour les erreurs d'omission) et Chêne Liège, Pin Maritime (pour les erreurs de commission) alors que la difficulté pour notre zone d'étude est effectivement de départager les couples de classes (chêne Zen, chêne Liège) et (Pin pignon, pin maritime). En effet, l'erreur d'omission pour notre système pour la classe Chêne Zen est de 0.2 alors que pour les autres méthodes, elle se situe entre 0,35 et 0,4. Pour le Pin Maritime, l'erreur d'omission pour notre système est de 0,37 alors que les autres méthodes

dégagent une erreur entre 0.67 et 1. De même, l'erreur de commission pour notre système pour la classe Chêne liège est de 0.25 alors que pour les autres méthodes elle se situe entre 0,46 et 0,57. Pour le Pin pignon l'erreur de commission pour notre système est inférieure à l'erreur engendrée par les quatre autres méthodes. Ceci s'explique par l'apport des techniques introduites et de la fusion contextuelle qui prend en considération la spécificité du cadre d'application et la redistribution des masses des unions sur les singletons des classes de manière à fournir un résultat avec un minimum de confusion.

Outre les couples de classes (Chêne liège, chêne zen) et (Pin Pignon, Pin Maritime), la classe Cyprès dégage aussi une erreur de commission de 0,8 par les méthodes M2 et M3 alors que notre système la minimise à 0. L'erreur de commission pour cette classe engendrée par les méthodes M4 et M5 est aussi proche de 0 grâce à l'intervention de la source S4.

VI.6.2 Analyse visuelle de la classification

Le résultat de la classification par les différentes méthodes est présenté dans les figures VI.30 à VI.34.

Les interprétations numériques précédentes sont basées sur les zones d'apprentissages extraites à partir de l'IHR. Toutefois, il est important d'évaluer le résultat de l'application des différentes méthodes avec la réalité du terrain. Ceci implique une comparaison du résultat de la classification avec une carte d'occupation ou à travers l'évaluation d'un expert. L'inventaire forestier dont nous disposons pour la zone d'étude n'apporte pas une précision fine au niveau des différentes espèces forestières. En effet, plusieurs polygones dans l'inventaire correspondent à une combinaison de classes qui correspondent aux espèces dominantes dans la zone inventoriée. Toutefois, il reste une base pour l'interprétation visuelle des résultats et l'analyse des affectations effectuées par les différentes méthodes dans la mesure qu'une bonne classification devra correspondre à l'une des espèces codées par le polygone.

La figure VI.30 montre le résultat de la classification par fusion des sources d'information obtenu à partir de notre système. Une comparaison avec l'inventaire forestier nous permet de constater que les deux espèces forestières chêne Zen et chêne Liège sont fidèlement reproduites et que les couronnes d'arbres correspondantes coïncident en général avec les polygones de l'inventaire. La même constatation est notée pour les Pin Pignon et Pin Maritime, qui malgré la forte similitude de leur niveau de gris dans l'image QuickBird, apparaissent en forte dominance dans les polygones correspondants.

Les figures VI.31 et VI.32 correspondent à la classification utilisant comme seules sources S1 et S2 pour les deux méthodes M1 et M2. Ce résultat illustre la limite de l'information spectrale et de texture pour départager les classes d'occupation. En effet, les classes Pin Pignon et Pin Maritime se trouvent confondues avec les zones agro forestières et la classe chêne Liège perd de sa dominance relativement aux polygones respectifs.

Les figures VI.33 et VI.34 présentent le résultat des deux méthodes M4 et M5. La classification par ces méthodes, bien que très proche de l'inventaire, fournit des résultats très influencés par la source S4 qui a masqué la spécificité radiométrique des couronnes incluses dans les mélanges et les a aboutit à une dominance en une seule classe.

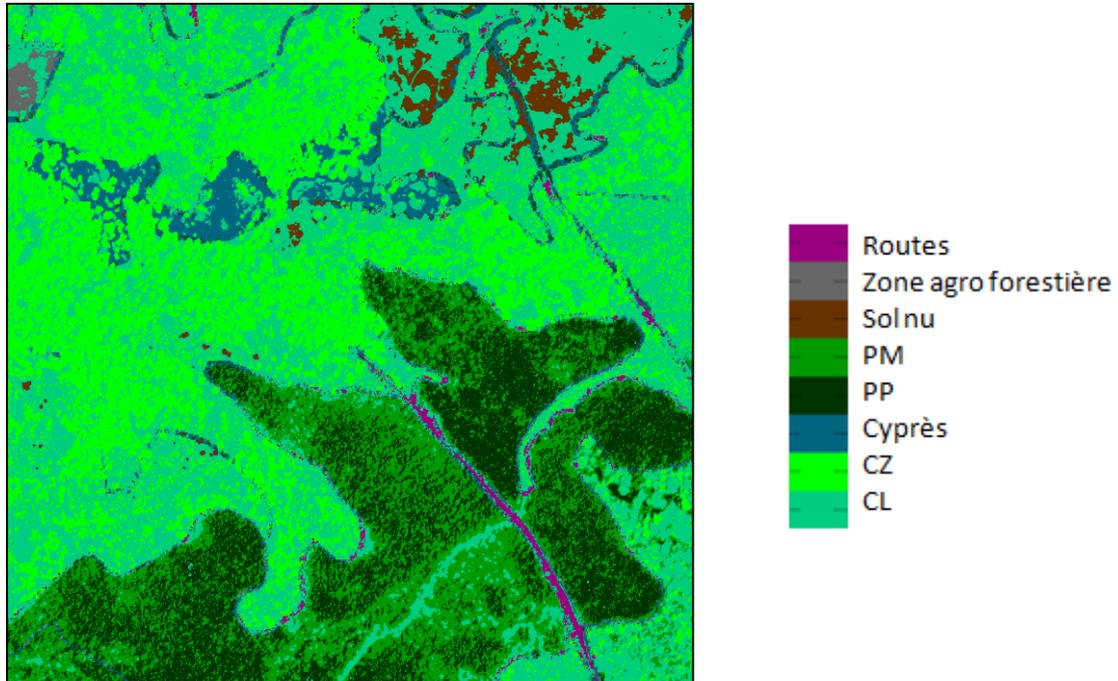


Figure VI.30. Classification par notre méthode M1 de la fenêtre f3

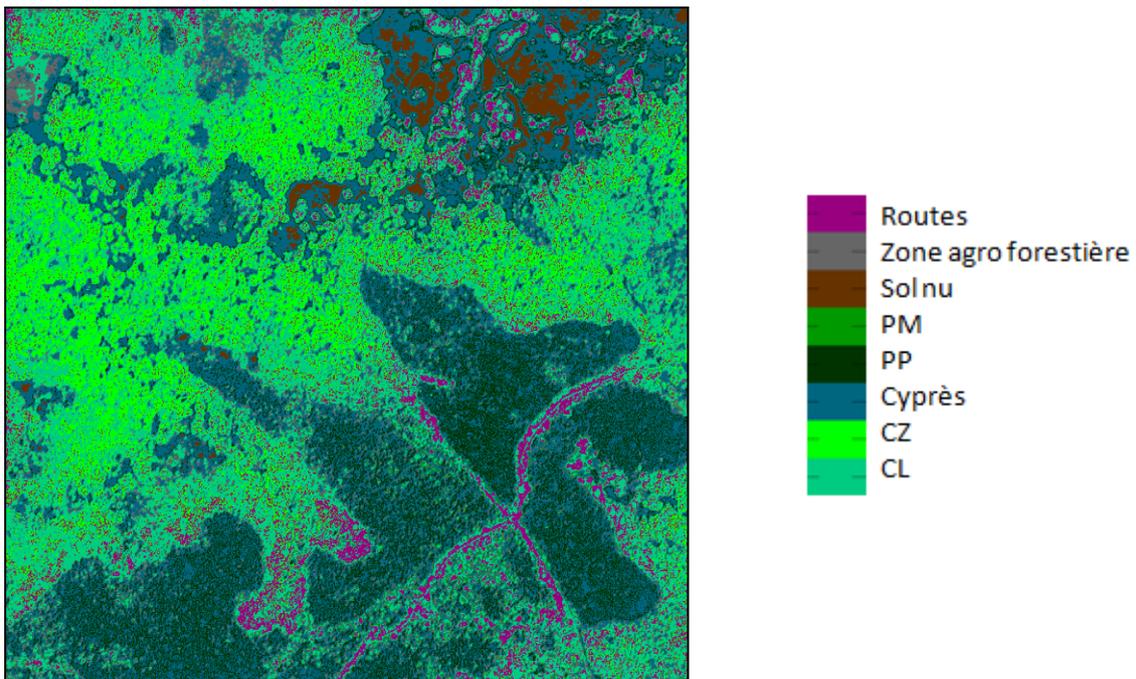


Figure VI.31. Classification par la méthode M2 la fenêtre f3

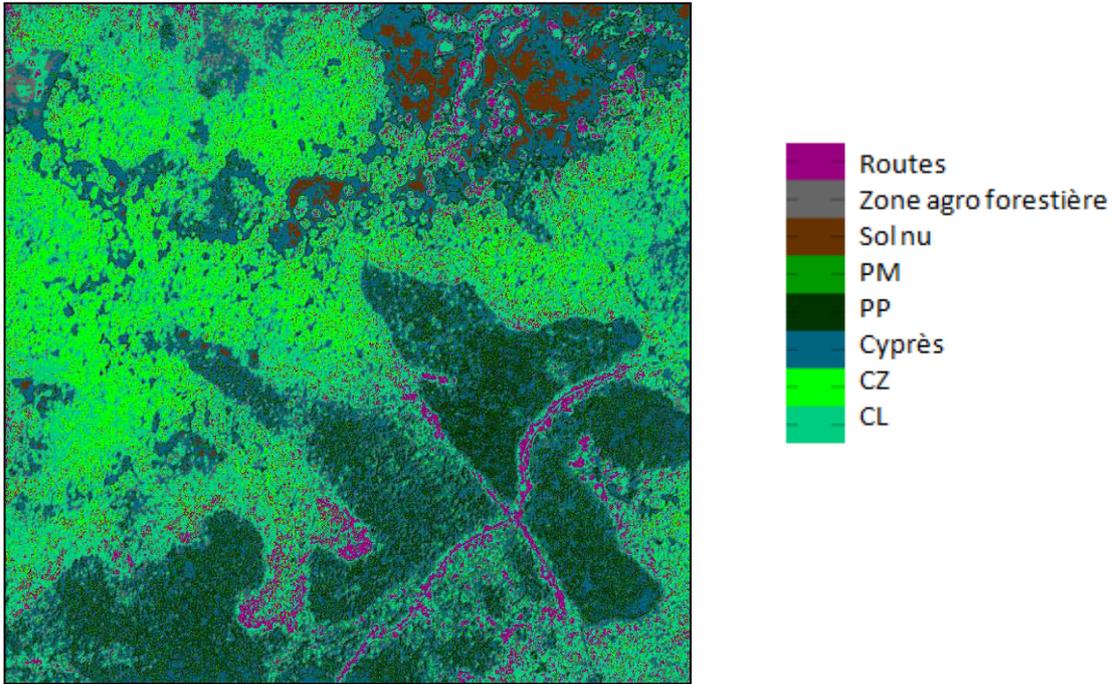


Figure VI.32 Classification par la méthode M3 de la fenêtre f_3

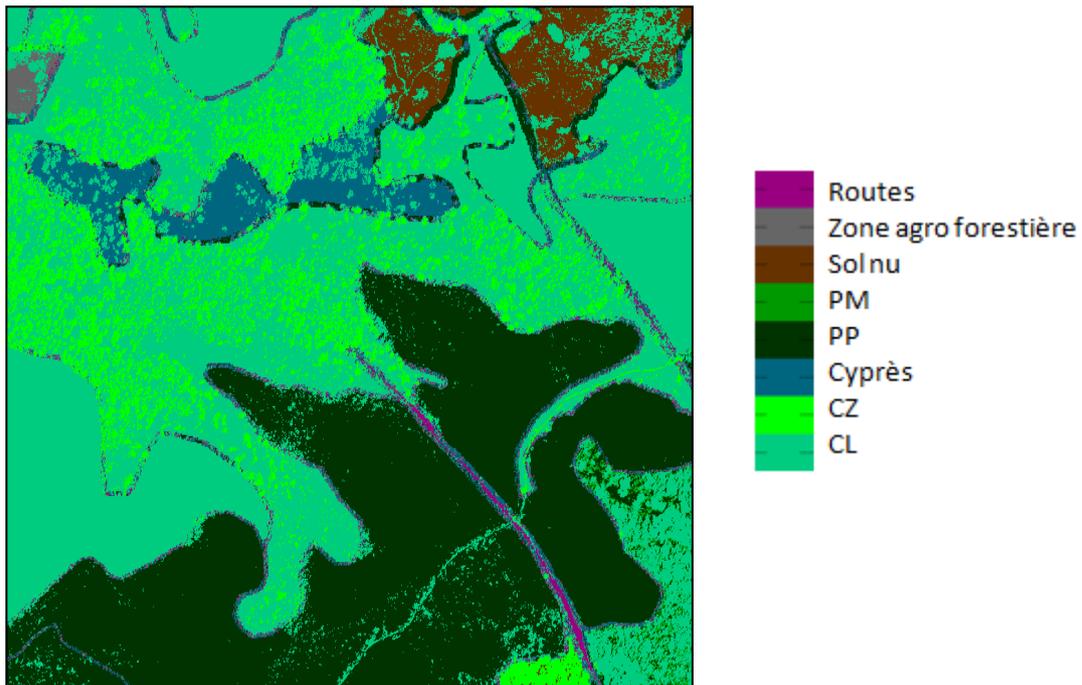


Figure VI.33. Classification la méthode M4 de la fenêtre f_3

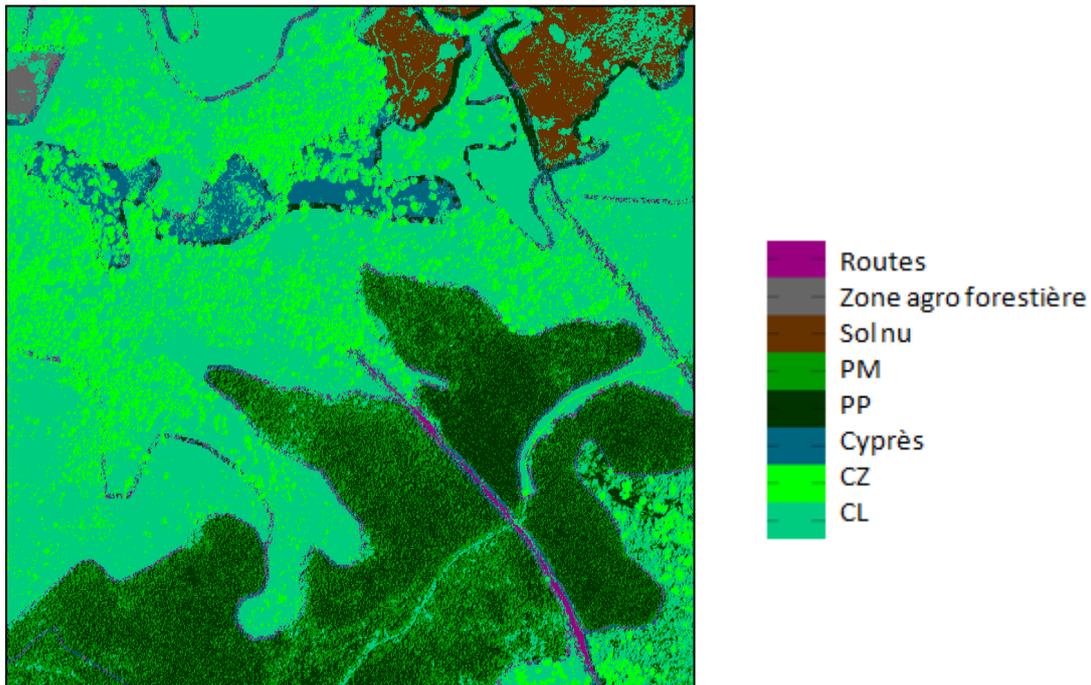


Figure VI.34. Classification la méthode M5 de la fenêtre f3

VI.7 Conclusion

Nos expérimentations sur des fenêtres de la source image QuickBird haute résolution ont mis en évidence les points suivants :

- La distinction entre certaines espèces peut être réalisée à travers l'information spectrale. Toutefois des problèmes de confusion persistent et le recours à d'autres sources est nécessaire pour affiner les résultats

- Dans le cas d'espèces caractérisées par leur différence texturale, l'approche d'estimation des fonctions de masses à partir des histogrammes de singularité s'avère plus efficace.

- Au niveau arbre, la décomposition en arbres permet de traiter chaque arbre ou couronne d'arbre à part et donc de prendre en considération les caractéristiques spectrale et/ou texturale de chacune, ce qui nous a permis de rajouter un nouveau critère de séparation entre les espèces forestières dans la classification à l'arbre près.

- Dans le cas d'une source supposée fiable tels que l'inventaire forestier numérisé dont nous disposons, cette source influe largement sur le résultat. D'où la nécessité de l'utiliser avec prudence.

L'évaluation de notre système de fusion et la comparaison des résultats qu'il fournit par rapport

à d'autres méthodes classiques nous permet de dégager les conclusions suivantes :

- L'efficacité et l'apport significatif de la fusion contextuelle que nous avons proposé. Ceci a été justifié par l'évaluation et la comparaison de quelques paramètres numériques comme le facteur Kappa et les erreurs d'omission et de commission.
- L'importance du choix des fonctions de masse pour chaque source et du formalisme de fusion de sources d'informations dans le processus de classification.
- L'apport d'une source dans la distinction d'une classe d'occupation varie selon le contexte, d'où la justification de notre approche de fusion dirigée par le contexte.
- On peut épargner l'étape d'estimation de la distribution de masses pour certaines sources (~~contextuelles~~) qui seront introduites dans une étape de révision d'une distribution de masses déjà calculée. Ceci a montré son efficacité pour guider à travers cette révision le résultat déjà obtenu à travers cette dernière distribution et permettra ainsi de retrouver une nouvelle distribution après révision par la source ~~contextuelle~~.

**CONCLUSION
ET
PERSPECTIVES**

CONCLUSION ET PERSPECTIVES

Le travail de cette thèse vise à proposer un système de fusion de sources d'information en utilisant la théorie des fonctions de croyances comme formalisme de fusion et les scènes forestières capturées par des satellites haute résolution comme application.

Nous avons choisi de travailler dans un cadre supervisé pour les expérimentations. Nous avons proposé une approche permettant d'utiliser l'ensemble des sources dont nous disposons pour combiner les informations issues de ces sources. Nous avons combiné ces sources de manière différente. En effet, en plus de la fusion des sources avec les opérateurs de combinaison, la révision d'une source par une autre a été implémentée et un transfert basé sur le contexte a été proposé prenant en compte de sources telles que l'inventaire forestier ou des sources déduites de l'image de télédétection et profitant de la haute résolution telle que l'image des couronnes.

Notre approche est fondée sur :

- (i) La proposition d'une méthode de réduction du référentiel de définition permettant de réduire la complexité des calculs de masses et d'éviter l'explosion combinatoire;
- (ii) La proposition de techniques d'estimation de fonctions de masse : spectrale, texturale, contextuelle et structurelle;
- (iii) L'exploitation d'une source déduite de l'image des couronnes d'arbres et la proposition d'une approche de transfert de masse basée sur l'information contextuelle intérieure et extérieure d'une couronne;
- (iv) La proposition d'une architecture d'un système de fusion basé sur un processus qui commence avec des prétraitements sur les sources initiales et qui aboutit à la classification des sources image haute résolution;

Nos contributions ont porté sur les points ci-dessous. Ainsi, nous avons tout d'abord proposé une méthode innovatrice permettant de déterminer les classes ou unions de classes « pertinentes » pour le calcul des fonctions de masses et par conséquent des fonctions de crédibilité qui en découlent. Se basant sur les histogrammes des échantillons représentatifs des classes et leurs chevauchements sur des intervalles de niveaux de gris, cette technique proposée ne retient qu'un nombre de sous ensembles de classes vérifiant des conditions qui dépendent de l'importance du chevauchement entre ces classes. La méthode proposée réduit considérablement le temps de calcul puisqu'il ne s'agit plus de calculer toutes les masses pour

exclure dans une deuxième phase les propositions (classes ou union de classes) de masses non nulles mais de restreindre le calcul sur les classes et les sous ensembles de classes du référentiel de définition réduit déterminé initialement à partir des histogrammes des classes issus de la phase d'apprentissage.

L'application de cette approche pour une zone d'étude et la comparaison des résultats à la réalité du terrain confirment à la fois l'efficacité de cette approche dans la résolution d'une partie du conflit entre classes et la rigueur du choix des éléments focaux pour la réduction du référentiel de définition qui s'est révélé important dans la réduction du temps d'exécution nécessaire pour les fonctions de masses combinées. Aussi, l'information de texture souvent omise dans le calcul des fonctions de masse s'avère importante et les comparaisons des matrices de confusions prouvent l'apport de l'utilisation des exposants de singularités de l'image Hölder dans l'amélioration de la qualité de la classification et la diminution de la confusion entre classes.

Nous avons implémenté des classifieurs mono-source afin de valider le choix des masses de croyance proposées et l'étude du conflit entre classes. Les résultats de ces classifieurs sur des fenêtres d'images moyenne et haute résolution ont été présentés, commentés et des conclusions ont été formulées concernant la réduction du temps de calculs et la précision dégagée à travers la source d'information.

Nous avons ensuite implémenté notre système de fusion multi sources basé sur la théorie des fonctions de croyance et appliqué sur des images forestières. L'architecture de ce système a été fondée sur l'enchaînement d'étapes qui conduisent à l'estimation de masses combinées et opérant avec l'utilisation de variables contextuelles pour le choix des sources.

Des algorithmes de détection de couronnes d'arbres ont été proposés, implémentés, commentés. L'étiquetage des couronnes dans l'image a permis d'extraire des mesures sur la couronne. Ces mesures sont utilisées en tant qu'attributs pour l'estimation des fonctions de masse de cette nouvelle source déduite.

Nos expérimentations ont montré des taux de classification assez satisfaisants avec les approches spectrale et texturale et une adéquation de notre approche de fusion à des informations contextuelle et structurelle pour une classification à l'arbre près.

Comme perspectives de ce travail nous pouvons citer ce qui suit :

Sur le plan théorique :

- La gestion du conflit est un domaine vaste qui a été traité sous plusieurs angles par les chercheurs. Ce volet a seulement été traité dans cette thèse au niveau du choix de sous

ensembles de sources selon le contexte. Une perspective serait de proposer des solutions de gestion de conflit basées sur les opérateurs adéquats et d'intégrer cette étape dans le processus de fusion.

- La complexité des calculs engendrés par le processus de fusion basé sur le formalisme de la théorie des fonctions de croyance nous amène à penser à un système multi agents pour le calcul des masses de croyances et leurs combinaisons. Ce système doit permettre une collaboration entre les différents agents afin de réduire encore la complexité et superviser notre processus de fusion en se basant sur les connaissances dont on dispose.
- Chercher la meilleure combinaison qui dégage un meilleur score de bonne classification d'une zone d'apprentissage pourrait être traitée en tant que problème de recherche opérationnelle, où les paramètres à minimiser sont les erreurs de classification dégagées de la matrice de confusion par exemple.

Sur le plan expérimental :

- Une intégration de plus de règles expertes pour une meilleure connaissance des espèces ainsi qu'une information sur l'altitude des arbres pourra orienter la classification de nouveau. Des perspectives d'intégration de ce travail au sein du ministère de l'agriculture tunisien avec adaptation totale aux besoins de l'inventaire forestier national est un projet en cours.
- Pour le cadre expérimental, notre travail peut être adapté pour l'estimation du volume en bois de la forêt par exemple puisque notre système de fusion fournit une classification à l'arbre près. Aussi, la détection de l'évolution de la forêt suite à des catastrophes naturelles (feu de forêts par exemple) est tout à fait possible.
- Une étude plus approfondie et/ou une proposition d'une nouvelle technique d'extraction des couronnes plus rapide et plus précise améliorera le résultat de la révision par la source image des couronnes.

Une généralisation de l'approche à d'autres types d'images tels que des images médicales ou des images issues du cadre industriel pour la surveillance de la qualité est aussi envisageable.

RÉFÉRENCES BIBLIOGRAPHIQUES

RÉFÉRENCES BIBLIOGRAPHIQUES

- [Abadi et Grandchamp 2006] M. Abadi et E. Grandchamp, *Texture features and segmentation based on multifractal approach*, Progress in Pattern Recognition, Image Analysis and Applications (CIARP), Cancun Mexico, Volume 4225, pages 297-305 - October 2006.
- [Aiqun 2005] C. Aiqun, *Application of the Information Fusion Based on Evidence Theory in Urban development*, 31^{ème} international symposium on remote sensing of environment. 131-137, Novembre 2005.
- [Altincay 2007] H. Altincay, *Ensembling evidential k-nearest neighbor classifiers through multi-modal perturbation*, Applied Soft Computing 7, pages 1072–1083, 2007.
- [Aurdal 1997] L. Aurdal, *Analysis of Multi-Image Magnetic Resonance Acquisitions for Segmentation and Quantification of Cerebral Pathologies*, Thèse de Doctorat, telecom Paris, department images, 24 mars 1997.
- [Barnett 1981] J.A. Barnett, *Computational methods for a mathematical theory of evidence*, Proceedings of IJCAI, pp 868-875, Vancouver, British Columbia, Canada. 1981.
- [Barra 2000] V. Barra, *Fusion d'Images 3D du Cerveau : Etude de Modèles et Applications*, Thèse de doctorat en informatique et traitement d'images, université Blaise Pascale, Faculté de Médecine, Juillet 2000.
- [Bauer 1997] M. Bauer, *Approximation Algorithms and Decision Making in the Dempster-Shafer Theory of Evidence-An Empirical study*, International Journal of Approximate Reasoning, vol 17, n° 2-3, pp. 217–237, 1997.
- [Bell et al. 2005] D.A. Bell, J. W. Guan et Y. Bi, *On Combining Classifier Mass Functions for Text Categorization*. pp. 1307-1319, vol n°17, 10 Octobre 2005.
- [Ben Amor et Martel 2004] S. Ben Amor et J-M. Martel, *Le choix d'un langage de modélisation des imperfections de l'Information en aide à la décision*, Faculté des Sciences. de l'administration, Université Laval, ASAC, Québec, 2004.
- [Ben Dhiaf et al. 2007 a] Z. Ben Dhiaf, J. Desachy et A. Hamouda, *Système de classification basée sur la théorie des fonctions de croyance*, Taima'07, Hammamet, Tunisie, 22-26 Mai 2007.
- [Ben Dhiaf et al. 2007 b] Z. Ben Dhiaf, J. Desachy et A. Hamouda, *Information sources fusion approach in forest stand classification*, SPIE, conference on "Image and Signal Processing for Remote Sensing", proceeding of SPIE vol. 67480V1-67480V10, Italie, 17-21 September 2007.
- [Ben Dhiaf et al. 2008 a] Z. Ben Dhiaf, A. Hamouda et J. Desachy, *Théorie des fonctions de croyance : Fondements, complexité et application à la classification d'images*, Conférence Internationale sur relations, ordres et Graphes (ROGICS'08) : Interaction avec l'Informatique, Mahdia, Tunisie, 12-17 Mai 2008.

- [Ben Dhiab et al. 2008 b] Z.Ben Dhiab, J.Desachy et A.Hamouda, *Management of the conflict between information sources in a fusion process: Application in forest cartography*, ISIVC'2008, 4th International Symposium on Image/Video Communications over fixed and mobile networks, Bilbao - Spain, July 9-11th.
- [Ben Dhiab et Sellaouti 2009] Z.Ben Dhiab et A.Sellaouti, *Système de classification d'images forestières haute résolution basé sur l'intégration des informations et des connaissances structurelles*, Taima'09, 4-9 Mai 2009, Hammamet Tunisie.
- [Ben Dhiab 2009] Z.Ben Dhiab, *Classification d'images de télédétection haute résolution de scènes forestière en utilisant la théorie des fonctions de croyances : Approche ponctuelle et approche région pour l'extraction des couronnes d'arbre*, la 6ème édition de la conférence STIC (Sciences et Technologies de l'Information et de la Communication) & ENVIRONNEMENT, Calais du 16 au 18 juin 2009.
- [Ben Dhiab et al. 2010] Z.Ben Dhiab , A.Hamouda et J.Desachy, *Integration of contextual information for the transfer of Beliefs in an information sources fusion system- Application to detection and classification of trees crowns*, ISPRS Commission VII Symposium : 100 Years ISPRS - Advancing Remote Sensing Science, Vienna University of Technology. July 5 - 7, 2010.
- [Ben Djebbour et al. 2001] A. Ben Djebbour, Y. Delignon, L. Fouque et al. , *Multisensor Image Segmentation Using Dempster-Shafer Fusion in Markov Fields Context*, IEEE Transactions on Geoscience and Remote Sensing Vol. 39, N°. 8, Août 2001.
- [Ben Tabet 2002] L. Ben Tabet, S. Jodouin et A-O. Boudraa, *Estimation of Mass Functions in Dempster-Shafer Evidence Theory using Fuzzy Clustering and Spatial Information for Gray Level Based Image Fusion*, Rapport de Recherche, Département de Mathématiques et d'Informatique, Université de Sherbrooke, Canada, 2002.
- [Ben Tabet et Maodong 2004] L. Ben Tabet et J. Maodong, *Iterative Markovian Estimation of Mass Functions in Dempster Shafer Evidence Theory: Application to Multisensor Image Segmentation*, Opt. Eng., Vol. 43, 1293, 2004.
- [Ben Tabet et Maodong 2008] L. Ben Tabet et J. Maodong, *A combined Markovian and Dirichlet sub-mixture modeling for evidence assignment: Application to image fusion*, Pattern Recognition Letters, doi:10.1016/j.patrec.2008.05.003, 2008.
- [Bloch 1996 a] I. Bloch, *Information Combination Operators for Data Fusion: A Comparative Review with Classification*, IEEE Transactions on Systems, Man, and Cybernetics, 26(1), pp 52-67, Janvier 1996.
- [Bloch 1996 b] I. Bloch, *Some Aspects of Dempster-Shafer Evidence Theory for Classification of Multi-Modality Medical Images Taking Partial Volume Effect into Account*, Pattern Recognition Letters, 17(8): 905-919, Juillet 1996.
- [Bloch 1996 c] I. Bloch, *Incertitude, imprécision et additivité en fusion de données : point de vue historique*, Traitement du Signal, Vol. 13 - n° 4, 1996.
- [Bloch et al. 1997] I.Bloch, Lars Aurdal, Domenico Bijno et al., *Estimation of class membership functions for gray-level based image fusion*, IEEE, 1997.
- [Bloch 2003 a] I.Bloch, *Probabilités: point de vue historique*, Module ITSI septembre 2003.

- [Bloch 2003 b] I. Bloch, *Fusion d'informations en traitement du signal et des images*, Hermès, Paris, France, 2003.
- [Bloch et maitre 2004] I. Bloch et H. Maitre, *Les méthodes de raisonnement dans les images*, TSI, CNRS UMR 5141 LTCI, Avril 2004.
- [Bloch 2005] I. Bloch, *Fusion d'informations numériques : panorama méthodologique*, Journées nationales de la Recherche en Robotique (JNRR'05), Guidel, Morbihan 5-7 octobre, 2005.
- [Bloch 2008] I. Bloch, *Defining belief functions using mathematical morphology—Application to image fusion under imprecision*, International Journal of Approximate reasoning, Vol. 48, Issue 2, pp. 437-465, 2008.
- [Boudraa et al. 2004] A-O. Boudraa, A. Bentabet, F. Salzenstein et al., *Dempster-Shafer's Basic Probability Assignment Based on Fuzzy Membership Functions*, Electronic Letters on Computer Vision and Image Analysis Vol. 4(1), pp. 1-10, 2004.
- [Boulila et al. 2007] W. Boulila, I. R. Farah, K. Saheb Etabaâ, et al. , Un système d'analyse d'images multicapteurs par fusion d'informations incertaines Interprétation d'images/Fusion d'informations. JS-EABA 2007 5èmes Journées Scientifiques de Borj el Amri 23-24 mai 2007.
- [Beucher et Lantuéjoul] S. Beucher et C.Lantuéjoul , *Sur l'utilisation de la ligne de partage des eaux en détection de contours*, Rapport interne N-598, Ecole des Mines de Paris, Centre de Morphologie Mathématique, Mai 1979.
- [Burrus 2003] N. Burrus, *Evidence Theory (part 1): Theoretical aspects*, LRDE Seminar, Mai 2003.
- [Caron et al. 2007] F.Caron, E.Duflos, C.Haas et al. , *Application du TBM pour la localisation de nœuds de communication à partir de mesures de proximité*, Revue Traitement du Signal, numéro spécial « la théorie des fonctions de croyance », Vol. 24, n° 2, pp 153-164, Avril 2007.
- [Corgne 2004] S. Corgne, *Modélisation prédictive de l'occupation des sols en contexte agricole intensif : application à la couverture hivernale des sols en Bretagne*. Thèse de Doctorat, Université de Rennes II. Décembre 2004.
- [Dempster 2008] A.P. Dempster, *The Dempster–Shafer calculus for statisticians*, International Journal of Approximate Reasoning, Vol.48 n° 2, pp.365-377, Juin, 2008.
- [Denoeux 1995] T. Denoeux. *A k-nearest neighbor classification rule based on Dempster-Shafer theory*, IEEE Transactions on Systems, Man and Cybernetics, 25(05):804-813, 1995.
- [Denoeux 1999] T. Denoeux. *Modélisation de l'imprécis et de l'incertain en apprentissage supervisé par la théorie des fonctions de croyance*, Rencontres Francophones sur la Logique Floue et ses Applications, pp.13-20, Valenciennes, Octobre 1999.
- [Denoeux 2001] T. Denoeux, *Inner and outer approximation of belief structures using a hierarchical clustering approach*, International Journal of Uncertainty, Fuzziness and Knowledge-Based Systems, vol. 9, no. 4, pp. 437 – 460, 2001.
- [Denoeux et Ben Yaghlane 2002] T. Denoeux et A. Ben Yaghlane. *Approximating the combination of belief functions using the fast Möbius transform in a coarsened frame*. International Journal of Approximate Reasoning, 31(1-2):77–101, October 2002.

- [Denoeux 2004] T. Denoeux, *Théorie des fonctions de croyance et classification*, Séminaire IRIT, Toulouse, 2 juin 2004.
- [Denoeux 2005] T. Denoeux, *Application du formalisme des fonctions de croyance en fusion d'informations et en classification*, Séminaire de l'Institut National de Recherche sur les Transports et leurs Sécurité (INRETS), Paris, Janvier 2005.
- [Desachy et al. 1996] J.Desachy, L. Roux et E. H. Zahzah. *Numeric and Symbolic Data Fusion: a Soft Computing Approach for Remote Sensing Images Analysis*. In: Pattern Recognition Letters, Elsevier, Vol. 17 N. 13, p. 1361-1378, novembre 1996.
- [Desachy et al. 2000] J. Desachy, H. Suzuki et V.Bessettes. *Pattern Recognition and Cooperation/Fusion Techniques: some Practical Issues*, conférence invitée. Image and Signal Processing for Remote Sensing VI, SPIE, Barcelone, Espagne. Septembre 2000.
- [Dezert 2002] J. Dezert, *Foundations for a new theory of plausible and paradoxal reasoning*, Information & Security, Tzv. Semerdjiev Editor, Bulgarian Academy of Sciences, Sofia, 2002.
- [Djiknavorian 2009] P. Djiknavorian, P. Valin et D. Grenier, *Dezet-Smarandache theory applied to highly conflictual reports for identification and recognition : Illustrative example of ESM associations in dense environments*, Defence R&D Canada – Valcartier, Rapport Technique, DRDC Valcartier TR 2008-537, Février 2009.
- [Dubois et Prade 1994] D. Dubois D et H. Prade, *La fusion d'informations imprécises*, Traitement du signal, 11(6):447458, 1994.
- [Duong 2005] M.H .Duong, *Modèles de précaution en économie: introduction aux probabilités imprécises*, Habilitation à Diriger des Recherches, 2005.
- [Elouadi et Ben Dhiaf 2009] I. Elouadi et Z. Ben Dhiaf, *Une approche coopérative multi agents pour la délimitation des couronnes d'arbres dans les images forestières haute résolution*, Taima'09, Hammamet Tunisie, 4-9 Mai 2009.
- [El-Shayeb 1999] Y. El-Shayeb, *Apport de la logique floue à l'évaluation de l'aléa « Mouvement de Terrain des sites géotechniques » : propositions pour une méthodologie générale*, Thèse de doctorat, Ecole Nationale Supérieure de Nancy, Mars 1999.
- [Erickson 2004 a] M. Erickson, *Species classification of individually segmented tree crowns in higher-resolution aerial images using radiometric and morphologic image measures*, Remote Sensing of Environment, Vol 91, pp 469-477, 2004.
- [Erickson 2004 b] M. Erickson, *Segmentation and Classification of Individual Tree Crowns in High Spatial Resolution Aerial Images*, Thèse de doctorat, Swedish University of Agricultural Sciences Uppsala, Sweden, 2004.
- [Farah 2008 et al. a] I.R. Farah, W. Boulila, B.K. Saheb Etabaâ et al., *Interpretation of multisensor remote sensing images: Multi-approach fusion of uncertain information*, IEEE Transactions on Geoscience and Remote Sensing, Vol. 46, No. 12, pp 4142-4152, December 2008.
- [Farah 2008 et al. b] I.R. Farah, W. Boulila, B.K. Saheb Etabaâ, et al., *Multi-approach system based on fusion of multi-spectral image for land cover classification*. IEEE Transactions on Geoscience and Remote Sensing, Vol. 46, No. 12, pp 4153-4161, December 2008.

- [Farah 2008 et al. c] I. R. Farah, W. Messoudi, K. S. Etabaâ et al. , *Satellite Image Retrieval Based On Ontology Merjin*. ICGST-GVIP Journal, Journal of Graphic Vision and Image Processing, ISSN: 1687-398 X , Vol.8, n°2, pp 45-53, July 2008.
- [Florea 2007] M.C. Florea, *Combinaison d'informations hétérogènes dans le cadre unificateur des ensembles aléatoires : approximations et robustesse*, Thèse présentée à la Faculté des études supérieures de l'Université Laval, 2007, Faculté des sciences et de génie, Québec, 2007.
- [Foucher et al. 2002] S. Foucher, M. Germain, J-M. Boucher et al., *Multisource Classification Using ICM and Dempster-Shafer Theory*, IEEE Transactions on Instrumentation and measurement, Vol. 51, n°. 2, Avril 2002.
- [Germain et al. 2004] M.Germain, J-M.Boucher, G-B. Béné et al. , *Fusion évidentielle multi-sources basée sur une nouvelle approche statistique floue*, EDAS International Symposium On Image/Video Communications over Fixed and Mobile Networks Paper Management System, 2004.
- [Gougeon 1995] F.A. Gougeon, *A crown-following approach to the automatic delineation of individual tree crowns in high spatial resolution aerial images*, Journal Canadien de télédétection, vol. 21, n° 3, pp 274-284, 1995.
- [Gougeon et Leckie 2003] F.A. Gougeon et D.G. Leckie, *Extraction d'information forestière à partir d'images à haute résolution spatiale en utilisant une méthode de reconnaissance individuelle des cimes d'arbres*. Rapport d'information, BC-X-369F. Centre de foresterie du Pacifique. Victoria, C.B. p 25, 2003.
- [Grazzini 2003] J. Grazzini, *Analyse multiéchelle et multifractale d'images météorologiques : Application à la détection de zones précipitantes*, PhD thesis, Thèse de doctorat, Université de Marne-la-Vallée, 2003.
- [Grazzini et al. 2006] J. Grazzini, A. Turiel et H. Yahia, *Multifractal formalism for remote sensing : a contribution to the description and the understanding of meteorological phenomena in satellite images*, World18 1re soumission à Revue Internationale de Géomatique Scientific Publishing, Singapore, chapter Complexus Mundi. Emergent Patterns in Nature, p. 247-256, 2006.
- [Grazzini et al. 2007] J. Grazzini, A. Turiel, H. Yahia et al. , *A multifractal approach for extracting relevant textural areas in satellite meteorological images*, Environmental Modelling and Software, vol. 22, n° 3, p. 323-334, 2007.
- [Gutiérrez et Farinas 2004] J.Gutiérrez et J.Farinas, *Stratégies de fusion de décisions multiexpert en identification automatique des langues*, MIDL (Modélisation pour l'identification des langues), Paris, ENST - Télécom Paris, ISSN 1242-5125, pp. 71-76, 29-30 novembre 2004.
- [Guo et al. 2006] H.Guo, W. Shi et Y.Deng, *Evaluating Sensor Reliability in Classification Problems Based on Evidence Theory*, IEEE Transactions on Systems, Man and Cybernetics-Part B: Cybernetics, Vol. 36, n° 5, Octobre 2006.
- [Haenni et Lehmann 2002] R. Haenni et N. Lehmann, *Resource-Bounded and Anytime Approximation of Belief Function Computations*, Elsevier Science, Février 2002.
- [Haenni et Lehmann 2003] R. Haenni et N. Lehmann, *Implementing Belief Function Computations*, international journal of intelligent systems , vol 18, 31-49, 2003.

- [Hammal et al. 2004] Z. Hammal, A. Caplier et M. Rombaut, *Classification d'expressions faciales par la théorie de l'évidence*, Logique Floue et Application (LFA'04), pp 173-180, Nantes – France, Novembre 2004.
- [Hammal et al. 2007] Z. Hammal, L.Couvreur, A. Caplier et al. , *Facial Expression classification: An approach based on the fusion of facial deformations using the transferable belief model*, International journal of approximate reasoning Vol n°46, pp 542-567, 2007.
- [Henry 2002] M. Henry, *Estimating ambiguity*, Discussion Papers from Columbia University, Department of Economics , N° 0102-21, 2002.
- [Hunter et Liu 2006] A.Hunter et W. Liu, *Fusion rules for merging uncertain information*, science direct Information Fusion 7, 97–134, 2006.
- [IFNT 2000] *Résultats du premier inventaire forestier national en Tunisie*, DGF, Ministère de l'Agriculture, République Tunisienne, 1995.
- [Janez 1996] F.Janez, *Fusion de sources d'informations définies sur des référentiels non exhaustifs différents : solutions proposées sous le formalisme de la théorie de l'évidence*, Thèse de Doctorat, Université d'Angers, France, Novembre 1996.
- [Jouan et Allard 2004] A. Jouan et Y. Allard, *Land use mapping with evidential fusion of features extracted from polarimetric synthetic aperture radar and hyperspectral imagery*, Information Fusion Vol 5, pp 251–267, 2004.
- [Jousselme et al. 2006] A-L. Jousselme, C. Liu, D. Grenier et al., *Measuring Ambiguity in the Evidence Theory*, IEEE Transactions on Systems, Man and Cybernetics-Part A: systems and humans, Vol. 36, n° 5, Septembre 2006.
- [Kaftandjian et al. 2003] V. Kaftandjian, O. Dupuis, D. Babot et al., *Uncertainty modelling using Dempster-Shafer theory for improving detection of weld defects*, Pattern Recognition Letters 24, 547–564, 2003.
- [Kennes 1992] R. Kennes, *Computational aspects of the Mobius transformation of graps*, IEEE Transactions on Systems, Man, and Cybernetics, vol. 22, no. 2, pp. 201–223, 1992.
- [Khedam et al. 2006] R. Khedam, A. Bouakache, G. Mercier et al. , *Fusion multirate à l'aide de la théorie de Dempster-Shafer pour la détection et la cartographie des changements : application aux milieux urbain et périurbain de la région d'alger*, revue Télédétection, Vol. 6, n°4, pp. 361-403, 2006.
- [Klir et Yuan 1995] G. J. Klir et B. Yuan, *Fuzzy Sets and Fuzzy Logic: Theory and Applications*, Upper Saddle River, NJ: Prentice-Hall, 1995.
- [Klir et Lewis 2008] G.J. Klir et H.W. Lewis, *Remarks on Measuring Ambiguity in the Evidence Theory*, IEEE Transactions on Systems, Man, and Cybernetics, Part A, Vol. 38, n°4, pp. 995 - 999, 2008.
- [Laha et al. 2006] A. Laha, N-R. Pal et J. Das, *Land Cover Classification Using Fuzzy Rules and Aggregation of Contextual Information Through Evidence Theory*, IEEE Transactions on Geoscience and Remote Sensing, Vol. 44, N° 6, Juin 2006.
- [Laporterie-Déjean 2003] F. Laporterie-Déjean, *Revue des méthodes de fusion d'images de télédétection de résolution spatiales différentes*, Bulletin SFPT n°169, Vol. 1, pp7-16, 2003.

- [Larsen et Rudemo 1997] M. Larsen et M. Rudemo, *Using ray-traced templates to find individual trees in aerial photographs*, Proc. of the 10th Scandinavian Conference on Image Analysis, Vol 2, pp 1007-1014, Lappeenranta, Finlande, 1997.
- [Lefevre 1999] E. Lefevre, *Using Information Criteria in Dempster-Shafer's Basic Belief Assignment*, Fuzzy Systems Conference Proceedings, Vol 1, pp 173 - 178, ISBN: 0-7803-5406-0, Seoul, South Korea, 22-25 aout 1999.
- [Lefevre et al. 2001] E. Lefevre, O. Colot, P. Vannoorenberghe et al. , *Informations et combinaison : les liaisons conflictuelles*, Revue traitement du Signal, Vol. 18, n°3, pp.161-177, 2001.
- [Lefevre et al. 2002] E. Lefevre, O. Colot et P. Vannoorenberghe, *Belief function combination and conflict management*, Information Fusion, Vol. 3, pp. 149–162, 2002.
- [Le Hégarat-Masclé et al. 1997] S. Le Hégarat-Masclé, I. Bloch et D. Vidal-Madjar, *Application of Dempster-Shafer Evidence Theory to Unsupervised Classification in Multisource Remote Sensing*, IEEE transactions on geosciences and remote sensing, Vol. 35, n° 4, Juillet 1997.
- [Le Hégarat-Masclé et al. 2003] S. Le Hégarat-Masclé, D.Richard et C.Ottlé, *Multi-scale data fusion using Dempster-Shafer evidence theory*, Integrated Computer-Aided Engineering, pp. 9-22 IOS Press 10, 2003.
- [Malpica et al. 2007] J.A.Malpica, M.C.Alonso et M.A.Sanz, *Dempster-Shafer Theory in geographic information systems: A survey*, Expert Systems with Applications Vol 32, pp 47–55, 2007.
- [Martin 2005] A.Martin, *La fusion d'informations*, Polycopié de cours ENSIETA - Réf. : 1484, Janvier 2005.
- [Martin et Osswald 2007] A.Martin et C.Osswald, *Une nouvelle règle de combinaison répartissant le conflit : Application en Imagerie Sonar et classification Radar*, Revue traitement du signal, Vol 24 n°2, pp71-81, Avril 2007.
- [Martin 2008] A. Martin, *La fusion d'informations*, support de cours, ENSIETA, Ecole Nationale d'Ingénieurs, Brest, 2008.
- [Mascarilla et al. 1993] L. Mascarilla, J. Desachy et E. H. Zahzah. *Compréhension d'images satellites. Utilisation de systèmes neuro-flous et de techniques de fusion d'informations multi-sources*. In: 4èmes Journées ORASIS'93, Mulhouse, 11-14 octobre 1993.
- [Masson 2005] M-H.Masson, *Apports de la théorie des possibilités et des fonctions de croyance à l'analyse de données imprécises*, Mémoire d'Habilitation à Diriger des Recherches, Décembre 2005.
- [Masson et Denoeux 2006] M-H Masson et T. Denoeux. *Inferring a possibility distribution from empirical data*, Fuzzy Sets and Systems 157(3) : 319-340, 2006.
- [Masson et Denoeux 2007] M-H Masson et T. Denoeux. *ECM : algorithme évidentiel des C-moyennes*, In rencontres Francophones sur la Logique Floue et ses Applications (LFA '07), pp 7-24, Nîmes, France, Cépaduès-Editions, Novembre 2007
- [Masson et Denoeux 2008] M.-H. Masson et T. Denoeux, *KECM : Une version noyau de l'algorithme évidentiel des C-moyennes*, In. Rencontres Francophones sur la Logique Floue et ses Applications (LFA '08), 2008.

- [Mercier et al. 2007] D.Mercier, G.Cron, T.Denoeux et al. , *Fusion de décisions postales dans le cadre du modèle des croyances transférables*, Revue Traitement du Signal, numéro spécial « la théorie des fonctions de croyance », Vol. 24, n° 2, pp. 133-151, Avril 2007.
- [Milisavljevic et Bloch 2003] N. Milisavljevic et I. Bloch, *Sensor Fusion in Anti-Personnel Mine Detection Using a Two-Level Belief Function Model*, IEEE Transactions on Systems, Man, and Cybernetics—Part C: Applications and Reviews, Vol. 33, n° 2, Mai 2003.
- [Naceur et al. 2000] M. S. Naceur, Z. Belhadj et M. R. Boussema. *Fusion de données satellitaires basée sur la théorie de Dempster-Shafer pour la cartographie et l'occupation du sol en milieu semi-aride*, Bulletin Société française de photogrammétrie et de télédétection, n°158, pp. 3-11, Saint-Mandé, France, 2000.
- [Muzy et al. 1993] J. F. Muzy, E. Bacry et A. Arneodo, *Multifractal formalism for fractal signals: The structurefunction approach versus the wavelet-transform modulus-maxima method*, Phys. Rev. E, vol. 47, n° 2, p. 875-884, 1993.
- [Nedelec et al. 2003] V.Nedelec, S.Corgne, V.Dubreuil et al., *Fusion de données de télédétection à l'aide de la théorie des évidences : Application au mato grosso en vue d'une spatialisation de la déforestation*, XI Simposio Brasileiro de Sensoriamento Remoto, Belo Horizonte, Avril 2003.
- [Omrani et al. 2006] H. Omrani, L. Ion-Boussier et P. Trigano, *Une approche hybride basée sur la logique floue et la théorie des croyances pour l'analyse des impacts liés à la mobilité urbaine*, LFA'2006, Rencontres francophones sur la Logique Floue et ses Applications, Toulouse, France, Octobre 2006.
- [Orponen 1990] P. Orponen, *Dempster's Rule of Combination is #P-Complete*, Artificial Intelligence, vol. 44, no. 1-2, pp. 245–253, 1990.
- [Osswald 2006] C. Osswald et A. Martin, *Understanding the large family of Dempster-Shafer theory's fusion operators: a decision-based measure*, The 9th International Conference on Information Fusion, Florence, Italy, 10-13 Juillet 2006.
- [Pieczynski 2004] W. Pieczynski, *Statistique, Fusion de Dempster–Shafer dans les chaînes triplet partiellement de Markov*, C. R. Acad. Sci. Paris, Ser. I 339, pp. 797–802, 2004.
- [Pearl 1986] J. Pearl. *Fusion, propagation, and structuring in belief networks*, Original Research Article Artificial Intelligence, Volume 29, Issue 3, September 1986, Pages 241-288
- [Perrin 2006] G. Perrin. *Etude du Couvert Forestier par Processus Ponctuels Marquées*. Thèse de Doctorat, Ecole doctorale de Centrale, Paris, France, 2006.
- [Perrin et al.2005] G.Perrin, X.Descombes et J. Zerubia, *Evaluation des ressources forestières à l'aide de processus ponctuels marquées*, Rapport technique, 2005.
- [Petiot et Dalle 2003] G.Petiot et P.Dalle, *Fusion de données pour l'aide à la prévision des crues*, 9^{ème} journées ORASIS 2003, LORIA, pp 433-441, Gérardmer, 19-23 mai 2003.
- [Petit-Renaud 1999] S. Petit-Renaud, *Application de la théorie des croyances et des systèmes flous à l'estimation fonctionnelle en présence d'informations incertaines ou imprécises*, Thèse de doctorat, Université de Technologie de Compiègne, Décembre 1999.

- [Pollock et Gillies 2000] J. L. Pollock et A.S. Gillies, *Belief Revision And Epistemology*, Revue Springer, vol. 122, n° 1-2 (22 ref.), pp. 69-92, 2000.
- [Provan 1989] G-M.Provan, *An Analysis of ATMS-Based Techniques for Computing Dempster-Shafer Belief Functions*, IJCAI, pp 1115-1120, 1989.
- [Rashidi et Ghassemian 2003] A.J.Rashidi et M. H.Ghassemian, *Extended Dempster-Shafer theory for multi-system/sensor decision fusion*, Proceeding of ISPRS, Challenges in Geospatial Analysis, Integration and Visualization, Stuttgart, September 8-9, 2003.
- [Régis et al. 2007] S. Régis, A. Doncescu et J. Desachy, *Théorie des fonctions de croyance pour la fusion et l'évaluation de la pertinence des sources d'informations: application à un bioprocédé fermentaire*, revue Traitement du signal, numéro spécial la théorie des fonctions de croyance, pp. 115-132, 2007.
- [Rombaut 2001] M. Rombaut. *Fusion : Etat de l'art et perspectives*, Technical Report DSP 99.60.078, Rapport DGA, 22 octobre 2001.
- [Rombaut et Zhu 2002] M. Rombaut et Y.M. Zhu, *Study of dempster-shafer theory for image segmentation applications*, Image and vision computing, Vol. 20, n°1, pp. 15-23, 2002.
- [Rouxet al. 1994] L.Roux, J.Desachy, L.Mascarilla et al. *Fusion d'informations multi-sources à l'aide de la théorie des possibilités : une application à la classification dans le domaine de la télédétection*. In: Interface to Real and Virtual Worlds, Montpellier, EC2, pp. 275-284, 7-11 février 1994.
- [Royère et al. 2003] C. Royère, M-E. El Najjar, V. Cherfaoui et al. , *Elaboration de fonctions de croyance à partir de données GPS et SIG-Etude de stratégies de fusion pour la localisation d'un véhicule*, TSI Technique et Science Informatiques, Vol. 22, n° 7-8, pp. 935-964, 2003.
- [Ruderman 1997] D. L. Ruderman, *Origins of scaling in natural images*, Vision Research, Vol. 37, n° 23, pp. 3385-3398, 1997.
- [Sentz et Ferson 2002] K. Sentz et S.Ferson, *Combination of Evidence in Dempster-Shafer Theory*, Sandia Report, Sand 2002-0835, Unlimited Release, Avril 2002.
- [Serra 1982] J. Serra , *Image analysis and mathematical morphology*, Academic Press, London, 1982.
- [Shafer 1976] G.Shafer, *A Mathematical Theory of Evidence*, Princeton University Press, 1976.
- [Shafer et Legan 1987] G.Shafer et R.Legan, *Implementing Dempster's rule for hierarchical Evidence*, Artificial Intelligence Journal Vol. 33 n°3, pp.271-298, 1987.
- [Shafer 1990] G.Shafer, *Perspectives on the theory and practice of belief functions*, International Journal of Approximate Reasoning, Vol 4, n° 5-6, pp 323 – 362, 1990.
- [Shafer 2001] G.Shafer, *Belief functions: Introduction*, Chapitre7, IJCAI Workshop on Reasoning with Uncertainty in Robotics, 2001.

- [Shenoy 1992] P.P. Shenoy, *Valuation based systems: A framework for managing uncertainty in expert systems*, In L.A. Zadeh and J. Kacprzyk, editors, *Fuzzy Logic for the Management of Uncertainty*, pages 83–104. John Wiley and Sons, 1992.
- [Smarandache 2004] F. Smarandache, *Unification of Fusion Theories (UFT)*, *International Journal of Applied Mathematics & Statistics*, 2, pp. 1-14, 2004.
- [Smarandache et Dezert 2004] F. Smarandache et J. Dezert, *Advances and Applications of DSMT for Information Fusion*. Collected works, American Research Press, Rehoboth, 418 p, 2004.
- [Smarandache et Dezert 2005] F. Smarandache et J. Dezert, *An introduction to DSMT Theory of Plausible, Paradoxist, Uncertain, and Imprecise Reasoning for Information Fusion*, 13th International Congress of Cybernetics and Systems, Maribor, Slovenia, Juillet, 2005.
- [Smarandache et Dezert 2006] F. Smarandache et J. Dezert, *Proportional Conflict Redistribution Rules for Information Fusion*, in *Advances and Applications of DSMT for Information Fusion*, Vol. 2, pp. 3–68, American Research Press, Rehoboth, 2006.
- [Smets 1990 a] P. Smets, *The transferable belief model and other interpretations of Dempster-Shafer's model*, *Uncertainty in Artificial Intelligence*, 1990.
- [Smets 1990 b] P. Smets, *The Combination of Evidence in the Transferable Belief Model*, *IEEE Transactions on Pattern Analysis and Machine Intelligence*, vol. 12, no. 5, pp. 447-458, May 1990.
- [Smets 1994] P. Smets, *What is Dempster-Shafer's model?*, John Wiley and Sons Inc., 1994.
- [Smets 1998] P. Smets, *Probability, Possibility, Belief : Which and Where*, *handbook of Defeasible Reasoning and Uncertainty Management Systems*, Vol. 1, pp 1-24, 1998.
- [Smets 2000] P. Smets, *Data Fusion in the Transferable Belief Model*, 2000.
- [Solaiman 2001] B. Solaiman, *Fusion de l'Information concepts et applications en imagerie*, TAIMA'01, Hammamet, Tunisie, 2001.
- [Straszecka 2006] E. Straszecka, *Combining uncertainty and imprecision in models of medical diagnosis*, *Information sciences* 176, pp. 3026-3059, 2006.
- [Straszecka 2008] E. Straszecka, *Combining Basic Probability Assignments for Fuzzy Focal Elements*, Springer – Verlag Berlin Heidelberg, ICAISC 2008, 9th International Conference Zakopane proceedings, Poland, 22-26, Juin 2008.
- [Suzuki et al. 2001 a] H. Suzuki, P. Matsakis et J. Desachy, *Exploitation de connaissances structurelles en classification d'images : utilisation de méthodes heuristiques d'optimisation combinatoire*, *Orasis 2001, Proc.*, pp. 455-464. Cahors, Juin 2001.
- [Suzuki et al. 2001 b] H. Suzuki, P. Matsakis et J. Desachy. *Fuzzy Image Classification and Combinatorial Optimization Strategies for Exploiting Structural Knowledge*. FUZZ-IEEE 2001, pp. 324-327, Australie, Décembre 2001.
- [Taleb-Ahmed et al. 2002] A. Taleb-Ahmed, L. Gautier et M. Rombaut, *Architecture de fusion de données basée sur la théorie de l'évidence pour la reconstruction d'une vertèbre*, *Traitement du Signal*, Vol. 19, n°4, pp. 267-283, 2002.

- [Tangestani et Moore 2002] M. H. Tangestani et F. Moore, *The use of Dempster–Shafer model and GIS in integration of geoscientific data for porphyry copper potential mapping, north of Shahr-e-Babak*, Iran, *International Journal of Applied Earth Observation and Geoinformation*, Vol. 4, pp 65–74, 2002.
- [Tesseem 1993] B. Tessem, *Approximations for efficient computation in the theory of evidence*, *Artificial Intelligence*, vol. 61, pp. 315–329, Juin 1993.
- [Thoma 1989] H. M. Thoma, *Factorization of belief functions*. Thèse de doctorat, Harvard University, Cambridge, MA, USA, 1989.
- [Tilie et al. 2007] S. Tilie, I. Bloch et L. Laborelli, *Fusion of complementary detectors for improving blotch detection in digitized films*, *Pattern Recognition Letters*, Vol. 28, n°13, pp.1735-1746, Octobre 2007.
- [Tupin et al. 1999] F. Tupin, I. Bloch et H. Maître, *A First Step Toward Automatic Interpretation of SAR Images Using Evidential Fusion of Several Structure Detectors*, *IEEE Transactions on Geoscience and Remote Sensing*, Vol. 37, n°3, Mai 1999.
- [Turiel et Parga 2000 a] A. Turiel et N. Parga, *The multifractal structure of contrast changes in natural images : from sharp edges to textures*, *Neural Computation*, vol. 12, n° 4, p. 763-793, 2000a.
- [Turiel et Parga2000 b] A. Turiel, N. Parga, *Multifractal wavelet filter of natural images*, *Physical Review Letters*, vol. 85, n° 15, p. 3325-3328, 2000b.
- [Vannoorenberghe 2003] P. Vannoorenberghe, *Un état de l'art sur les fonctions de croyance appliquées au traitement de l'information*, *Revue Information, Interaction, Intelligence*. 13, Vol. 3, n° 2, pp. 9-45, 2003.
- [Vannoorenberghe et al. 2003] P. Vannoorenberghe, E. Lefevre et O. Colot, *Traitement d'images et théorie des fonctions de croyance*, *Rencontre Francophone sur la Logique Floue et ses Application*, LFA'2003, pp.287-294, 2003.
- [Véhel et Vojak 1995] J.L. Véhel et R. Vojak, *Multifractal Analysis of Choquet Capacities: Preliminary Results*, Rr-2576, INRIA, 1995.
- [Voorbraak 1989] F. Voorbraak, *A computationally efficient approximation of Dempster-Shafer theory*, *International Journal of Man-Machine Studies*, 1989.
- [Wu et al. 2006] X. Wu, Q. Ye et Y. Chen, *Combination Method for Dempster-Shafer Evidence Based on Priority Factors*, *Proceedings of the 6th World Congress on Intelligent Control and Automation*, Dalian, China, Juin 2006.
- [Yager 1987] R. Yager, *On the Dempster-Shafer framework and new combination rules*. *Information sciences*, Vol. 41, pp. 93-138, 1987.
- [Yen 1990] J. Yen, *Generalizing the Dempster-Shafer theory to fuzzy sets*. *IEEE Transactions on Systems, Man, and Cybernetics*. Vol. 20, n° 3, pp. 559-570, 1990.
- [Yong et al. 2003] H. Yong, G. Jun, H. Liang-Mei et al., *A new method of determining the basic belief assignment in D-S evidence theory*, *Proceedings of the Second International Conference on Machine Learning and Cybernetics*, Vol.5, pp 3208 – 3211, ISBN: 0-7803-8131-9, Xi'an, Chine, 2-5 November 2003.

- [Zhu et al. 2002] Y. M. Zhu, L. Benthabet, O. Dupuis et al., *Automatic determination of mass functions in Dempster-Shafer theory using fuzzy c-means and spatial neighborhood information for image segmentation*, Optical Engineering, Vol. 41, n° 4, pp. 760–770, Avril 2002.
- [Zhu et Basir 2003] H. Zhu et O. Basir, *A Scheme For Constructing Evidence Structures In Dempster-Shafer Evidence Theory For Data Fusion*, IEEE International Symposium on Computational Intelligence in Robotics and Automation, Kobe, Japan, Juillet 2003.
- [Zhu et Basir 2005 a] H. Zhu et O. Basir. *An Adaptive Fuzzy Evidential Nearest Neighbor Formulation for Classifying Remote Sensing Images*, IEEE Transactions on geoscience and remote sensing, Vol. 43, n° 8, pp. 1874-1889, Août 2005.
- [Zhu et Basir 2005 b] H. Zhu et O. Basir, *A Fuzzy Evidential Reasoning Data Fusion Approach with Uncertainty Evaluation for Robust Pattern Classification*, IEEE Transactions on geoscience and remote sensing, Vol. 43, n° 8, pp. 773 – 778, Août 2005.
- [Zouhal et Denoeux 1996] L. M. Zouhal et T. Denoeux. *Reconnaissance de Formes Floues par la Théorie de Dempster et Shafer*. In Rencontres Francophones sur la Logique Floue et ses Applications, pp. 3-8, Nancy, Décembre 1996.

ANNEXE A

REGLES DE GESTION DU CONFLIT

ANNEXE A

Règles de gestion du conflit

Cet annexe se base essentiellement sur les travaux et synthèses de J.Dezert et F.Smarandache [Dezert 2002],[Smarandache 2004],[Smarandache et Dezert 2004],[Smarandache et Dezert 2005], [Smarandache et Dezert 2006], M.C Florea [Florea 2007], E. Lefevre [Lefevre et al. 2001],[Lefevre et al. 2002] et A.Martin [Martin 2005],[Martin et Osswald 2007],[Martin 2008].

A.1 Alternatives à la règle de Dempster

Même si la règle de Dempster est utilisée pour un nombre varié d'applications, dans la présence d'un conflit élevé entre les informations à combiner, cette règle donne des résultats contre-intuitifs (Exemple de Zadeh). Pour pallier à ce problème, plusieurs règles de combinaison ont été proposées [Hunter et Liu 2006]. La majorité des règles proposées ne sont pas associatives. Dans cette section nous présentons les règles les plus connues. La plupart des règles proposées redistribuent de manières différentes la masse de l'ensemble vide. Certains auteurs critiquent le développement de nouvelles règles de combinaison, car selon eux, il s'agit plutôt d'une mauvaise modélisation du problème ou d'un problème mal posé, tandis que d'autres auteurs sont en faveur des alternatives à la règle de Dempster [Florea 2007].

Combinaison de sources non fiables : Le conflit peut être généré par un défaut de fiabilité d'une partie des sources d'information. Cet argument a été repris dans le cadre des opérateurs présentés par Yager et par Dubois et Prade.

A.1.1 Opérateur de Yager

Dans le cas de l'opérateur de Yager, on suppose que l'une des sources intervenant dans la combinaison est fiable. Ainsi, la solution est obligatoirement dans le référentiel. Mais ne sachant quelle source donne la vraie solution, Yager propose d'attribuer la masse conflictuelle K à l'ensemble Ω (redistribuer la masse de l'ensemble vide à l'ignorance) [Yager 1987]. La masse résultante de cette combinaison, pour deux sources d'information, est obtenue de la manière suivante selon l'équation (A.1):

$$\begin{cases} m^{S_1, S_2}(\Phi) = 0 \\ m^{S_1, S_2}(A) = (m^{S_1} \wedge m^{S_2})(A) \\ m^{S_1, S_2}(\Omega) = (m^{S_1} \wedge m^{S_2})(\Omega) + (m^{S_1} \vee m^{S_2})(\Phi) \end{cases}, \forall A \subset \Omega, A \neq \Phi \quad (\text{A.1})$$

Yager a aussi proposé une version quasi-associative de sa règle pour la combinaison de M sources. Au lieu de réaliser une combinaison séquentielle de la règle donnée par les équations ci-dessus avec une normalisation après chaque combinaison, il propose de réaliser la combinaison conjonctive (qui est associative) des M fonctions de masse et redistribuer le conflit final seulement. Il est possible d'utiliser cette technique pour rendre quasi-associatives la plupart des règles de combinaison pour la DST basées sur des règles associatives telles que la conjonctive ou la disjonctive. Notons qu'une approche similaire proposée par Yager repose sur l'introduction d'une nouvelle hypothèse dans le cadre de discernement. Cette hypothèse va supporter toute la masse conflictuelle. En outre, on peut remarquer que les opérateurs supposant que les sources sont fiables reposent principalement sur une combinaison conjonctive.

A.1.2 La combinaison proposée par Dubois et Prade

Nous rappelons les règles de combinaison conjonctive et disjonctive :

$$\text{Combinaison conjonctive : } (m^{S_1} \wedge m^{S_2})(A) = \sum_{B \cap C = A} m_1(B) \times m_2(C)$$

$$\text{Combinaison disjonctive : } (m^{S_1} \vee m^{S_2})(A) = \sum_{B \cup C = A} m_1(B) \times m_2(C)$$

La combinaison proposée par Dubois et Prade dans le cadre de la fusion de deux sources d'information $\{S_1, S_2\}$, peut s'expliquer de la manière suivante. Soit S_1 une source soutenant la proposition B avec une masse de croyance $m^{S_1}(B)$ et soit une source S_2 soutenant la proposition C avec une masse de croyance $m^{S_2}(C)$.

Lorsque les propositions soutenues par ces deux sources sont contradictoires et ne sachant pas quelle source est fiable, le principe de minimum de spécificité impose de redistribuer la masse associée à cette contradiction, soit $m^{S_1}(B) \times m^{S_2}(C)$, sur l'union des propositions c'est-à-dire $B \cup C$ [Dubois et Prade 1994]. En 1988, Dubois et Prade ont proposé de redistribuer la masse de l'ensemble vide $m^{S_1, S_2}(\Phi)$ non seulement aux éléments focaux obtenus par la règle conjonctive $F_{1 \wedge 2}$, mais aussi à certains éléments focaux obtenus par la règle disjonctive $F_{1 \vee 2}$. Quand l'intersection des éléments focaux de m^{S_1} et m^{S_2} est vide, la masse qui devrait être allouée à l'ensemble vide est transférée à l'union des deux éléments focaux.

L'opérateur de Dubois et Prade est alors défini pour deux sources d'information comme l'illustre l'équation (A.2) suivante :

$$\begin{cases} m^{S_1, S_2}(\Phi) = 0 \\ m^{S_1, S_2}(A) = (m^{S_1} \wedge m^{S_2})(A) + \sum_{\substack{B \cup C = A \\ B \cap C = \Phi}} m_1(B) \times m_2(C) \quad \forall A \subset \Omega, A \neq \Phi \end{cases} \quad (\text{A.2})$$

A.1.3 Affaiblissement

Une autre méthode, reposant sur la définition de coefficients d'affaiblissement, permet de gérer la combinaison de sources non fiables. Soit une fonction de croyance m^{S_j} fournie par une source S_j et un coefficient α_j qui représente la degré de confiance que l'on accorde à la source . On obtient alors le formalisme suivant :

- $\alpha_j=0$ signifie une remise en cause totale de la fiabilité de S_j ,
- $\alpha_j=1$ signifie une confiance absolue en la source S_j .

On note alors $m_{\alpha_j}^{S_j}$, la fonction de croyance m^{S_j} affaiblie par un coefficient $(1-\alpha_j)$. Cette fonction est définie ainsi par l'équation (A.3) qui suit:

$$\begin{cases} m_{\alpha_j}^{S_j}(A) = \alpha_j m^{S_j}(A) & \forall A \subset \Omega \\ m_{\alpha_j}^{S_j}(\Omega) = 1 - \alpha_j m^{S_j}(\Omega) \end{cases} \quad (\text{A.3})$$

De cette manière, lorsque nous avons une confiance totale en la fiabilité de la source , l'information apportée par cette source ne devrait pas engendrer de conflit lors de la combinaison. Le coefficient est dans ce cas égal à 1 et la fonction de croyance n'est alors pas modifiée. Au contraire, si l'on suppose qu'une source S_j est non fiable, lors de la combinaison avec d'autres sources celle-ci peut alors produire une information conflictuelle.

En introduisant un coefficient $\alpha_j = 0$, la fonction de croyance m^{S_j} associée à la source S_j devient alors une fonction de croyance d'ignorance totale ($m_{\alpha_j}^{S_j}(\Omega)=1$) et donc élément neutre pour la combinaison de Dempster. Ainsi l'intérêt de l'affaiblissement est de maîtriser l'influence des sources d'information selon leur fiabilité avant de les combiner. Plusieurs méthodes ont été développées afin de définir les coefficients d'affaiblissement.

A.1.4 Approches de redistribution du conflit (PCR) : Proportional conflict redistribution

Smarandache et Dezert ont développés des approches de redistribution du conflit (5 modèles de PCR1 à PCR5) [Dezert 2002], [Smarandache et Dezert 2004]. Ces modèles ont pour but de redistribuer le conflit partiel créé par la règle conjonctive, entre deux fonctions de masse, aux éléments focaux qui sont à la base de ce conflit partiel. Les équations (A.4) décrivent le jeu de masse considéré par la règle PCR5 qui est la dernière et la meilleure des 5 versions selon ses

auteurs :

$$\left\{ \begin{array}{l} m_{PCR}(\Phi)=0 \\ m_{PCR}(A)=(m^{S_1} \wedge m^{S_2})(A) + \sum_{A \cap B = \emptyset} \left[\frac{m^{S_1}(A)2m^{S_2}(B)}{m^{S_1}(A)+m^{S_2}(B)} + \frac{m^{S_2}(A)2m^{S_1}(B)}{m^{S_2}(A)+m^{S_1}(B)} \right] \end{array} \right. \quad (A.4)$$

Si un dénominateur est nul, alors la fraction est rejetée. Les mêmes auteurs de la PCR5, proposent aussi une version quasi-associative de cette règle de combinaison (qui est donnée pour M sources). Une deuxième version quasi-associative pour la combinaison de M sources est proposée par Martin et Osswald [Martin et Osswald 2007] sous le nom PCR_{MO} (ou PCR6) et possède un comportement plus intuitif que la version proposée par Smarandache et Dezert.

A.1.5 Règle de combinaison adaptative (ACR) : Adaptive Combination Rule

Dans [Florea 2007], l'auteur définit une nouvelle classe de règles adaptatives (ACR), dans le cadre unificateur des ensembles aléatoires, qui réalise la combinaison d'informations en conflit élevé et même total, ainsi que la combinaison d'informations qui sont en accord. L'auteur étudie plus précisément un cas particulier de cette règle adaptative avec des fonctions de pondérations symétriques (ACRS), décrite selon l'auteur comme unique en son genre.

La classe ACR permet tout aussi bien la combinaison d'informations en conflit élevé et même total, que d'informations qui sont en accord. Elle manipule des cadres de discernement non-exhaustifs différents et homogènes ou non-exclusifs. Elle s'appuie sur l'hypothèse que le conflit entre les informations est directement relié à la fiabilité relative des sources. Ainsi, elle utilise une pondération entre la règle conjonctive et celle disjonctive en fonction du conflit entre les deux ensembles aléatoires à combiner.

Bien d'autres règles sont citées et commentées dans [Florea 2007] telles que la classe unifiée des règles de combinaison de Inagaki. En 2002, Lefevre et al. [Lefevre et al. 2002] ont proposé une méthode d'apprentissage automatique des coefficients liés aux règles de Inagaki.

A.1.6 Classification des règles de combinaison

Une classification des règles de combinaison pour la DST a été proposée dans [Florea 2007] et ceci selon plusieurs propriétés (algébriques ou non). Ainsi, l'auteur a étudié des propriétés algébriques (commutativité, associativité, idempotence, continuité, impact neutre de l'ignorance) et des propriétés telles que : la possibilité de combiner des informations en provenance de sources moins fiables (lorsque le degré de fiabilité n'est pas connu), la possibilité de combiner des informations définies sur des cadres de discernement non-exhaustifs différents.

Nous avons rappelé dans ce document les définitions des règles de combinaison pour 2 sources, mais elles sont étendues pour M sources. L'ensemble des équations de combinaison pour M sources est cité dans [Martin et Osswald 2007].

A.2 Cadre générique pour les opérateurs de combinaison

Dans la littérature, un certain nombre de solutions pour l'interprétation du conflit sont proposées. Les auteurs dans [Lefevre et al. 2001] proposent un cadre générique pour unifier ces différents opérateurs de combinaison. En outre, ce cadre nous permet de définir d'autres opérateurs destinés à permettre une redistribution de la masse conflictuelle de manière locale, adaptée ou répondant à des objectifs précis.

ANNEXE B

ZONE D'ETUDE ET SOURCES D'INFORMATIONS DISPONIBLES

ANNEXE B

Zone d'étude et sources d'informations disponibles

Dans cette annexe, nous présentons la zone d'étude et les sources d'information dont on dispose, nous relevons ainsi les spécificités du cadre forestier et les problèmes que pose la fusion de sources d'information dans ce cadre.

B.1 Zone d'étude

La zone d'étude considérée est une région forestière située dans la ville d'Ain-Drahim du gouvernorat de Jendouba (Tunisie), une zone d'étude forestière au nord de la Tunisie comme le représente la figure B.1.

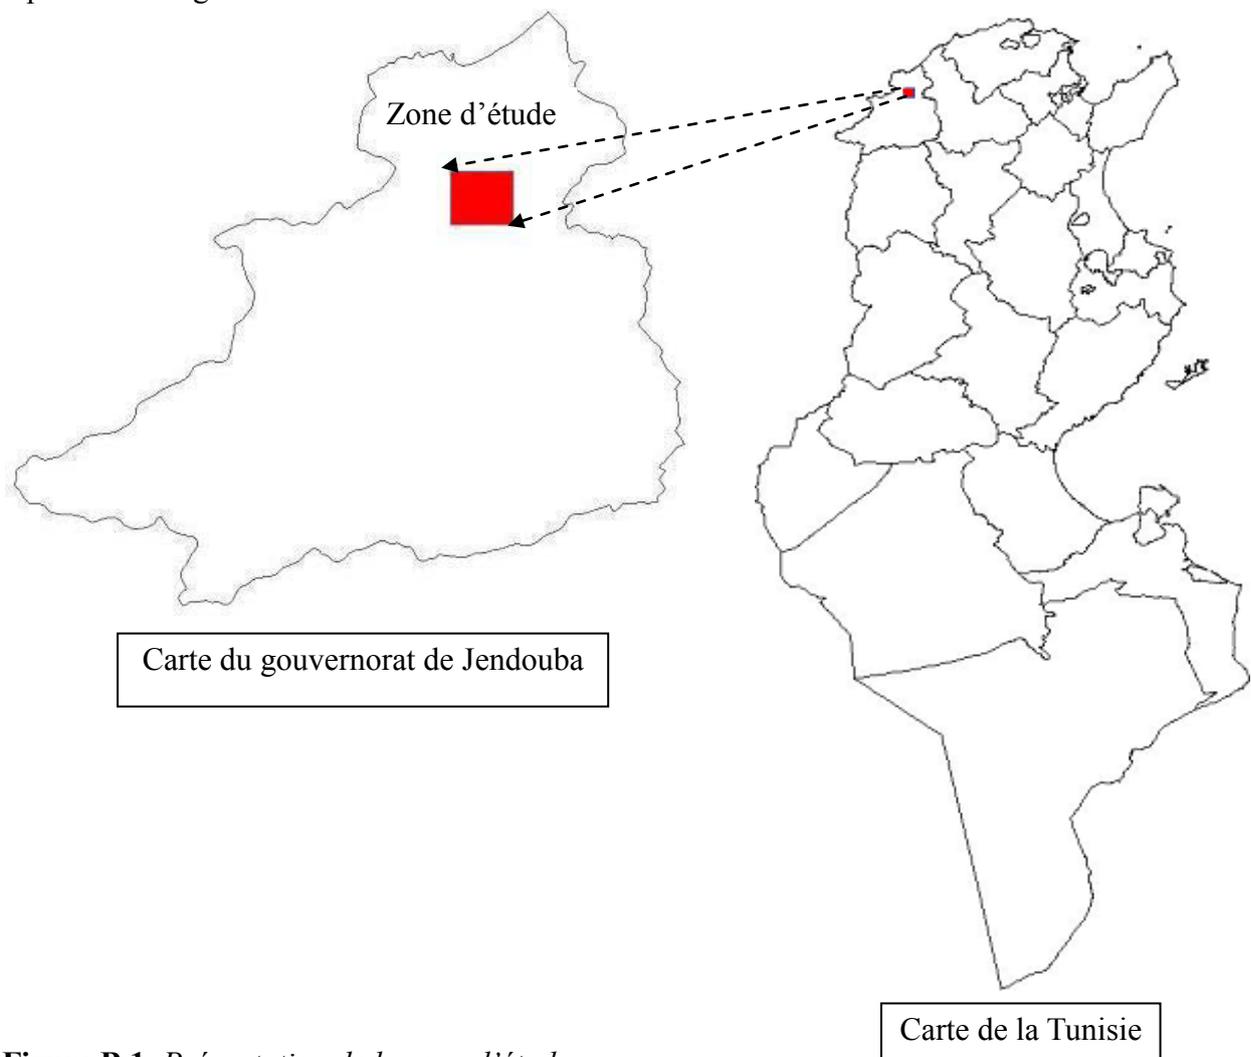


Figure B.1. *Présentation de la zone d'étude.*

Les raisons du choix de la zone d'étude sont la diversité de strates, l'abondance des espèces forestières ainsi que les variations d'altitude. Cette application s'intègre dans un intérêt national pour une cartographie actualisée de la couverture forestière pour l'exécution de plans d'interventions.

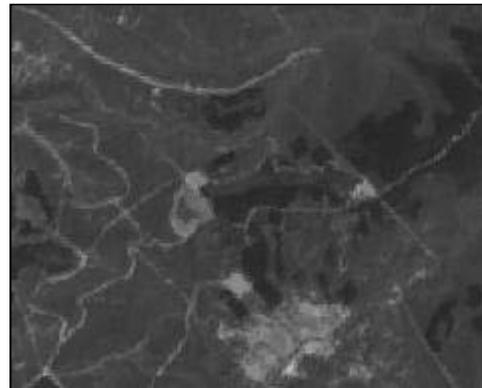
B.2 Sources d'informations

Les sources d'informations dont on dispose dans le cadre de ce travail sont :

- Une image QuickBird haute résolution
- Une image Spot moyenne résolution
- Le Modèle Numérique du Terrain (MNT) de la scène
- Deux inventaires forestiers numérisés réalisés à des dates différentes.

B.2.1 Image SPOT moyenne résolution

Nous disposons d'une image SPOT moyenne résolution (10mètres/pixel) qui date de 2001 comme le montre la figure B.2.



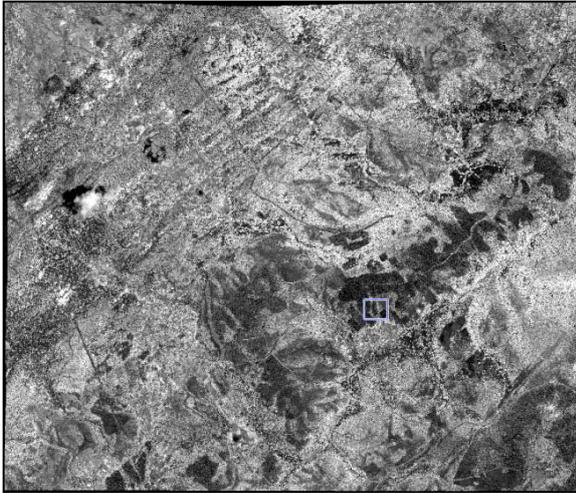
(a) : Image SPOT moyenne résolution

(b) : Fenêtre en résolution réelle de l'IMR

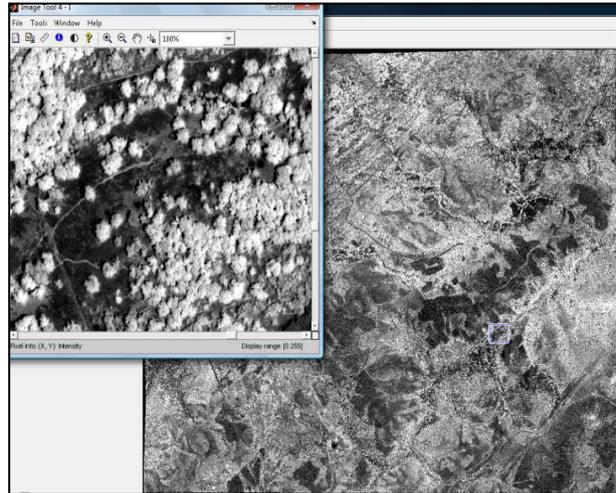
Figure B.2. *Présentation de l'Image Spot moyenne résolution de notre zone d'étude.*

B.2.2 Image QuickBird très haute résolution

Nous disposons d'une image Quickbird haute résolution (0.61mètres/pixel) qui date de juin 2006.



(a) : Image QuickBird, bande PIR



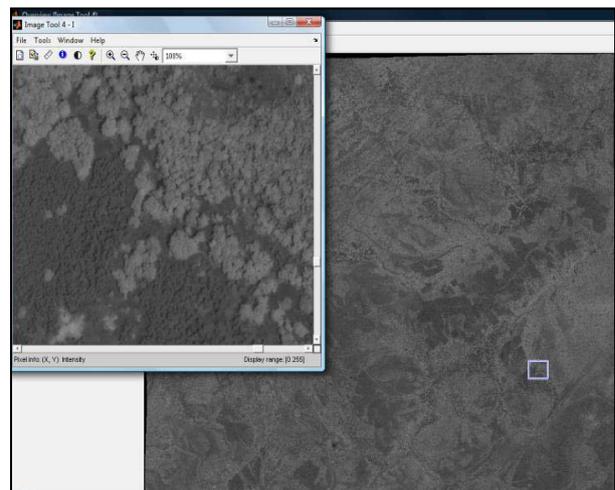
(b) : Fenêtre de l'IHR, bande PIR



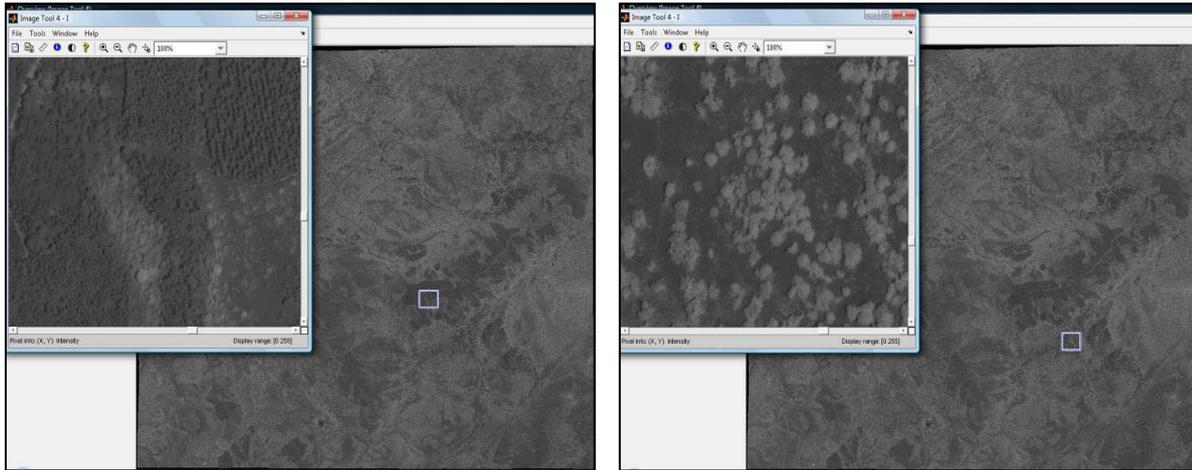
(c) : Fenêtre de l'IHR, bande PIR



(d) : Image QuickBird de la scène d'étude, image orthorectifiée



(e) : Fenêtre de l'IHR



(f) : Fenêtre de l'IHR

(g) : Fenêtre de l'IHR

Figure B.3. Image QuickBird de la scène d'étude et quelques fenêtres de cette image.

Les figures B.3 montrent des vues de cette image (B.3(a) et B.3(d)) pour les bandes PIR et pour l'image ortho rectifiée et des fenêtres en résolution réelle qui montre la précision.

B.2.3 Inventaire Forestier National (IFN)

Nous disposons de deux inventaires :

- L'inventaire Forestier et Pastoral National 2000
- L'inventaire Forestier et Pastoral National 1990

Ces inventaires ont été fournis par la Direction de la Forêt du ministère de l'agriculture. Ils ont fait l'objet d'un appel d'offre international et ont été exécutés à travers des images aériennes et une codification sur le sol qui permet de retrouver pour chaque polygone de l'image vectorielle des informations sur l'espèce forestière inventoriée. L'inventaire est basé sur la notion de stratification. Une strate étant définie comme une fraction représentative d'une population. La figure B.4 représente l'IFN décomposé en strates ainsi que la légende des couleurs utilisée. La figure B.5 montre une fenêtre de l'IHR ainsi que l'inventaire correspondant en strates.

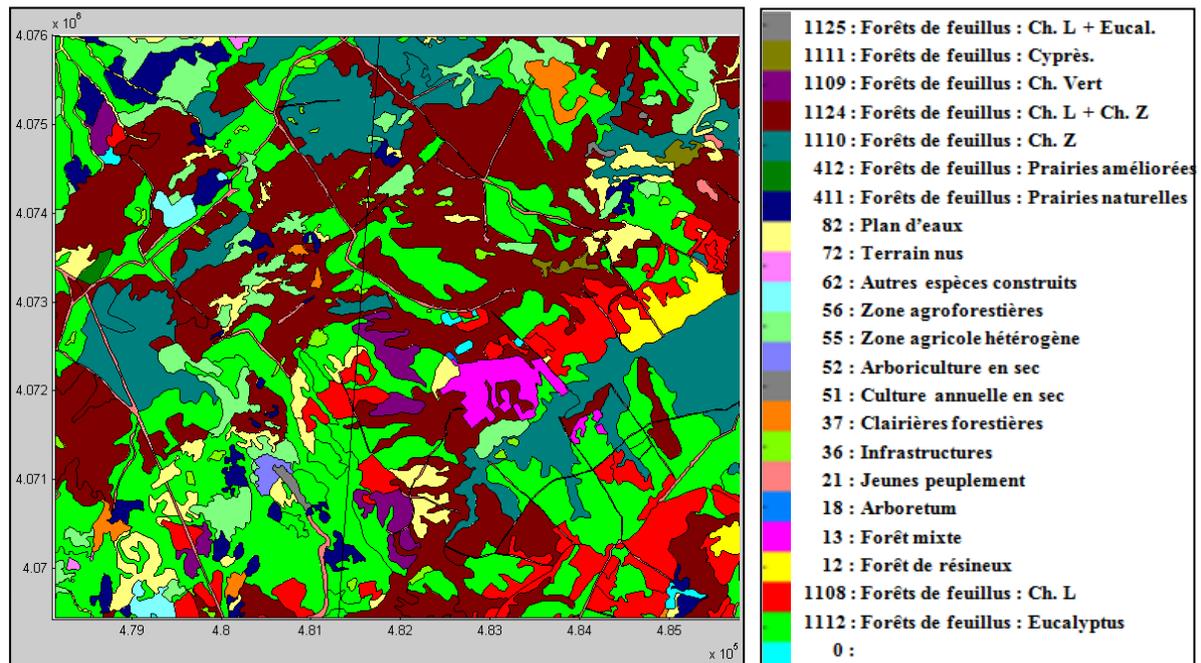
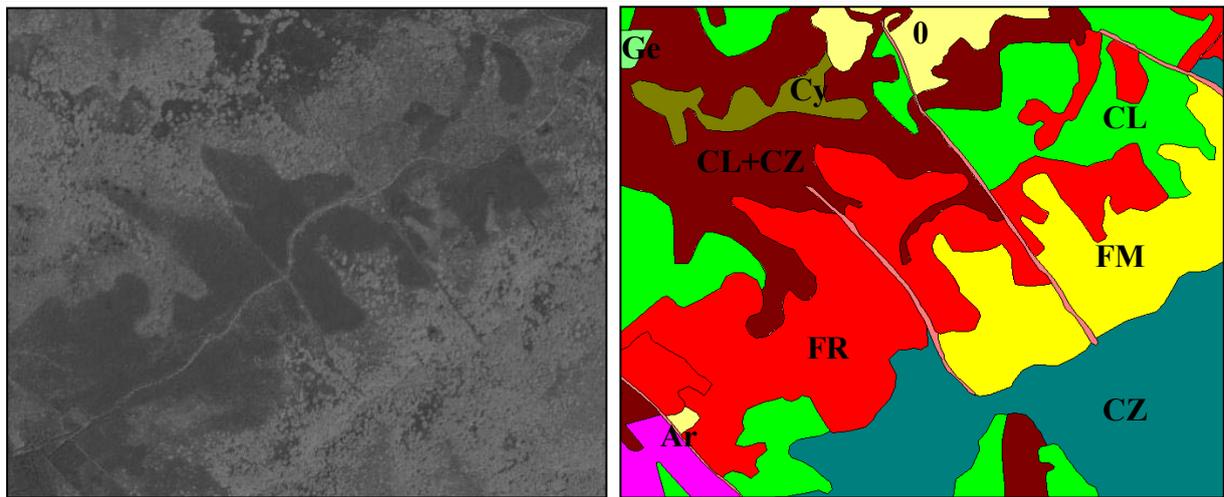


Figure B.4. Inventaire de la zone d'étude en strates.

Les abréviations pour les espèces existantes dans notre zone d'étude et qui seront utilisées dans ce rapport sont les suivantes : *CL* : Chêne liège, *CZ* : Chêne Zen, *FM* : Forêt mixte, *FR* : forêt de résineux, *Ar* : Arboretum, *Cy* : Cyprès, *Ge* : Genévrier, *0* : non forêt.

Les renseignements attendus de l'élaboration d'un inventaire forestier sont des renseignements quantitatifs et qualitatifs sur toutes les forêts du pays et par essence forestière. Ces renseignements sont principalement les suivants :

- Densité des peuplements,
- Dimensions des arbres,
- Volume et accroissements des bois,
- Biomasse ligneuse et herbacée,
- Classes de fertilité (accroissement en hauteur et âge).



(a) : Fenêtre de l'IHR

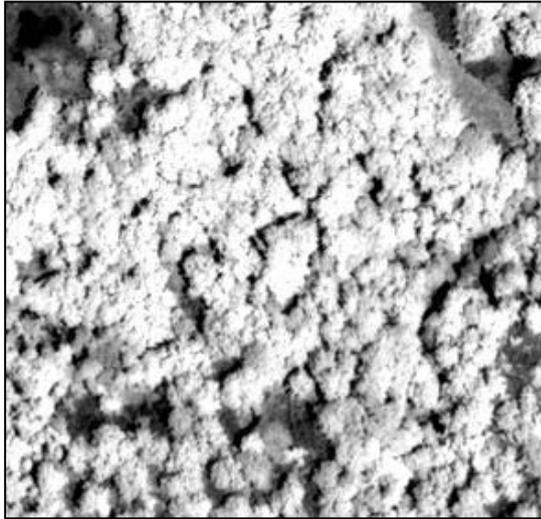
(b) : Inventaire correspondant étiquetée

Figure B.5. Inventaire correspondant à une fenêtre de l'image QuickBird

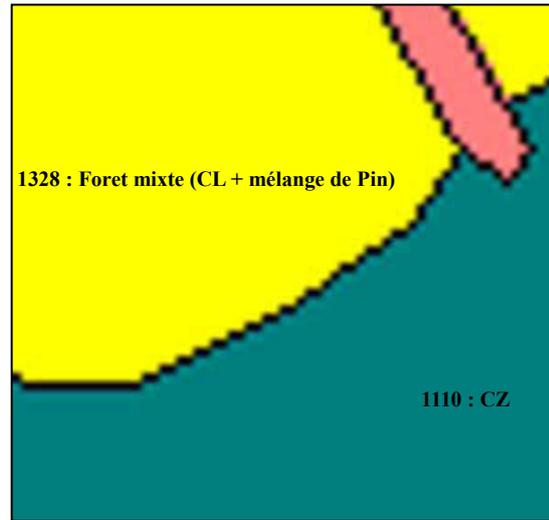
La réalisation d'un inventaire nécessite des investissements importants, des moyens humains, du temps (des années: survol, organismes, appel d'offre) et se base sur des images aériennes coûteuses et nécessitant des autorisations des autorités administratives.

Cependant, la prolifération des moyens d'acquisition de données de télédétection et l'émergence de systèmes satellitaires de haute résolution nous emmène à nous orienter vers l'utilisation d'images haute résolution pour tirer profit des connaissances disponibles. Notre recherche a été orientée vers une cartographie automatique pour dégager les espèces, leurs densités et d'autres informations pertinentes pour le gestionnaire de l'espace forestier.

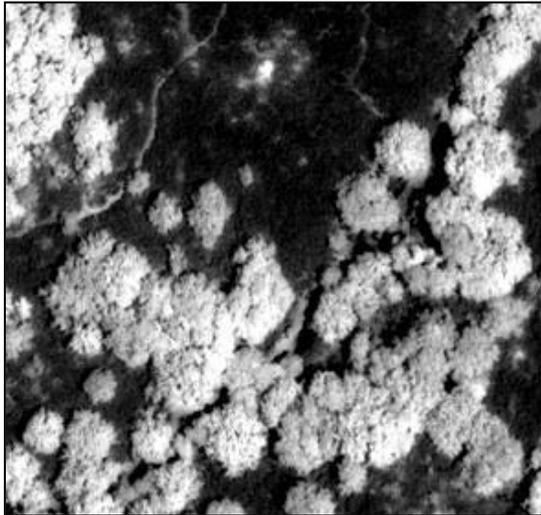
Les figures B.6 suivantes illustrent le niveau de détail apporté par l'inventaire forestier, on y présente des fenêtres de l'image QuickBird et l'inventaire ramené à la même résolution. Toutefois, si la délimitation des frontières dans l'image de l'inventaire entre les différents regroupements semble correspondre à la réalité du terrain, il est à noter que la précision du contenu en espèces reste relative, étant donné la haute résolution de l'image QuickBird. La richesse de l'image haute résolution s'avère un élément clé capable d'apporter un meilleur traçage de l'occupation terrestre à l'arbre près. L'inventaire numérisé informe aussi sur un état temporel grossier d'une couverture en strate et en type qui peut se manifester comme source fiable et pertinente dans un système de cartographie automatique.



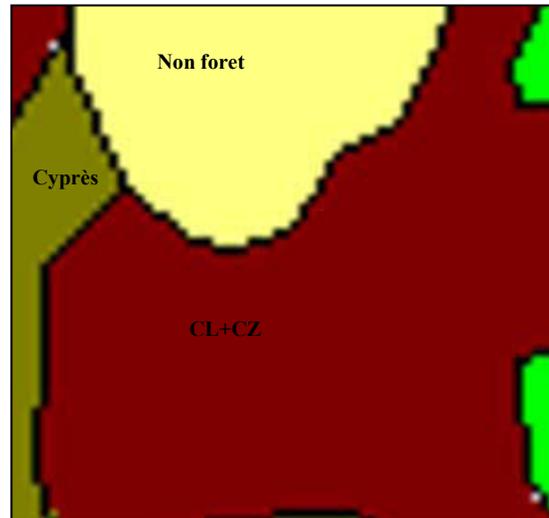
(a): fenêtre (i) de l'IHR



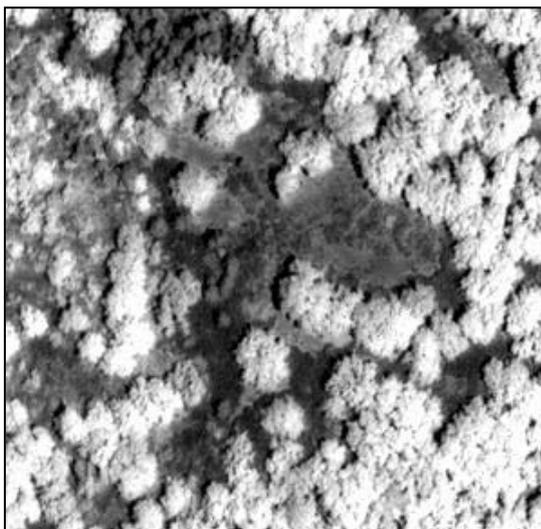
(b) : inventaire correspondant à la fenêtre (i)



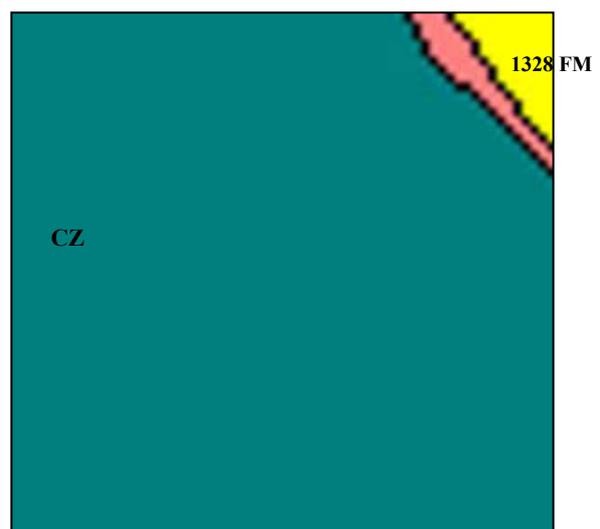
(c): fenêtre (ii) de l'IHR



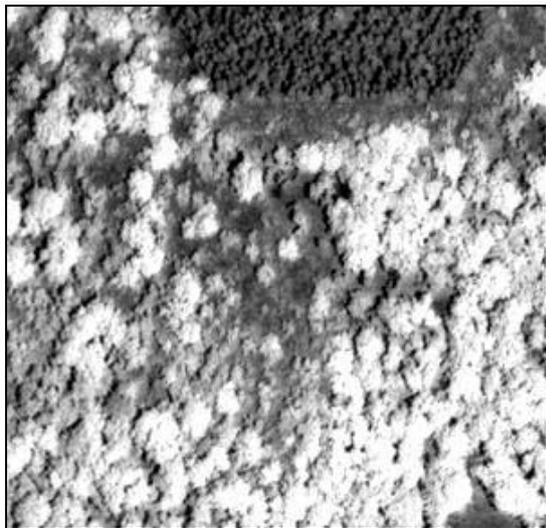
(d) : inventaire correspondant à la fenêtre (ii)



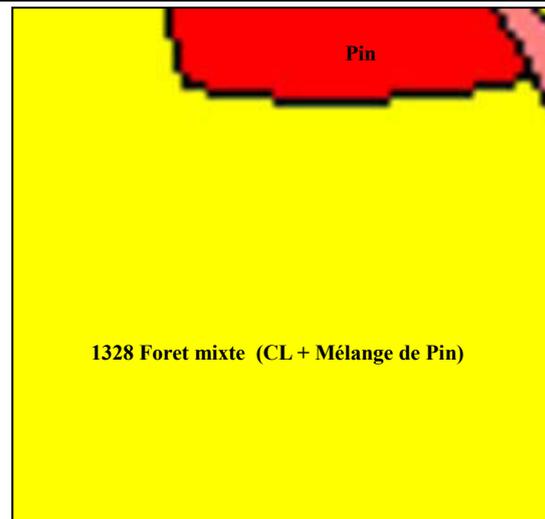
(e): fenêtre (iii) de l'IHR



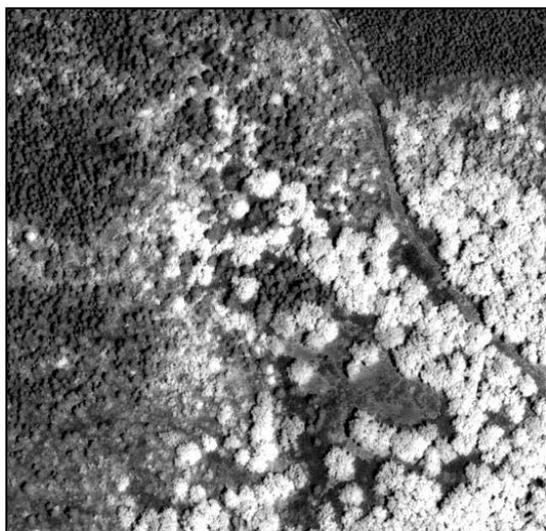
(f) : inventaire correspondant à la fenêtre (iii)



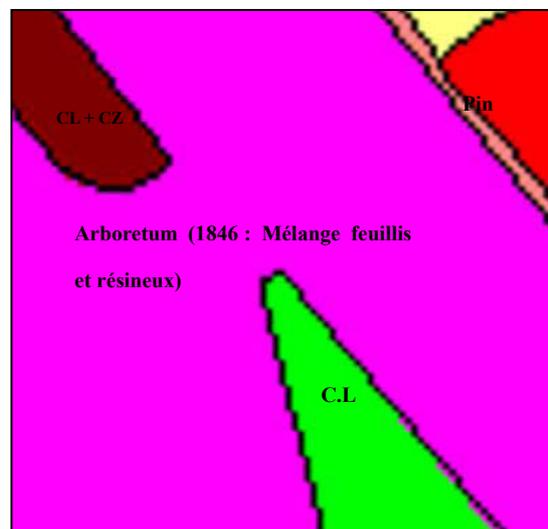
(g): fenêtre (iiii) de l'IHR



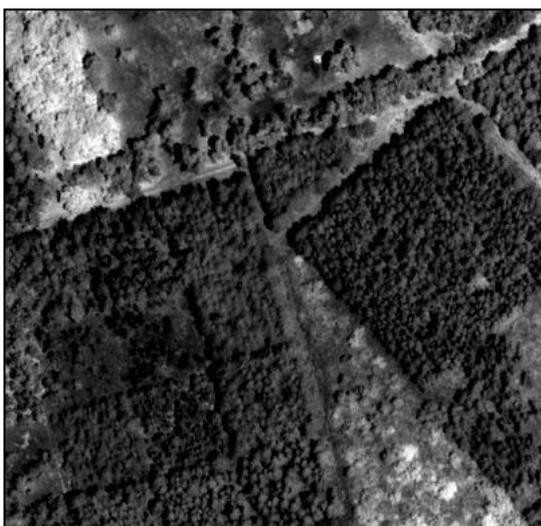
(h) : inventaire correspondant à la fenêtre (iiii)



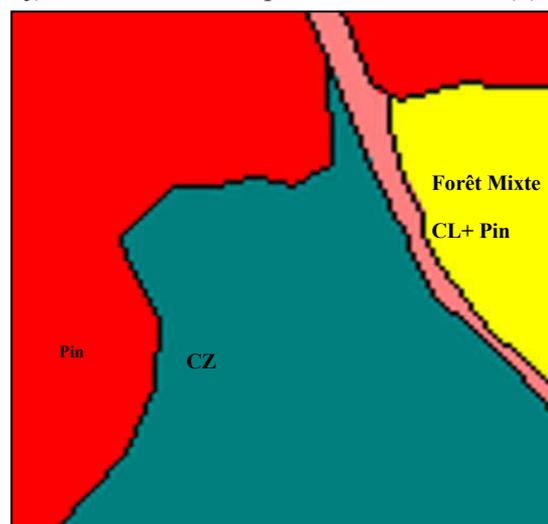
(i): fenêtre (v) de l'IHR



(j) : inventaire correspondant à la fenêtre (v)



(k): fenêtre (vi) de l'IHR



(l) : inventaire correspondant à la fenêtre (vi)

Figure B.6. Exemples de fenêtres de l'IHR et inventaires correspondants.

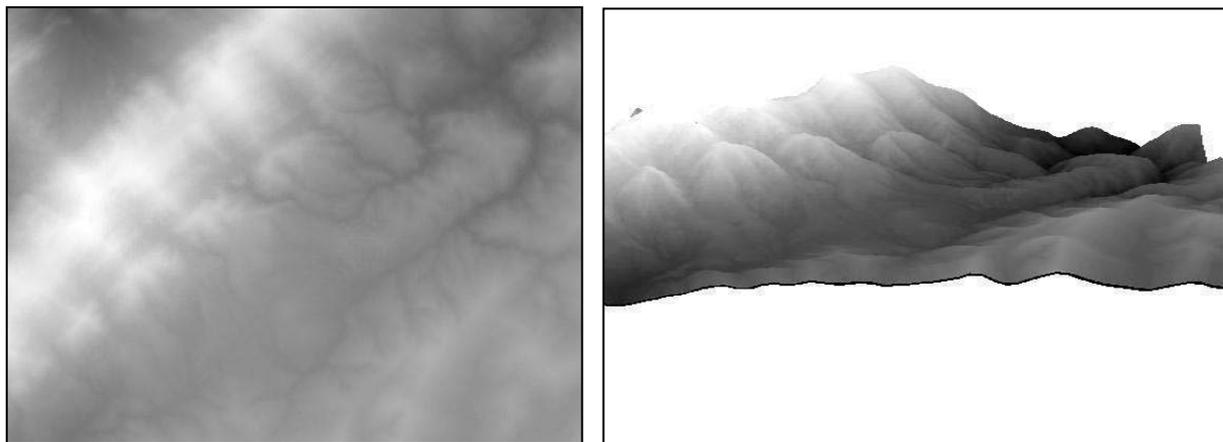
B.2.4 Le Modèle Numérique du Terrain (MNT)

Un Modèle Numérique de Terrain (MNT) est une carte indiquant la forme brute du terrain, sans construction ni végétation. Il correspond donc à la topographie de la région étudiée.

Le MNT est une représentation numérique simplifiée de la surface d'un territoire, en coordonnées altimétriques (le plus souvent exprimées en mètres par rapport au niveau de la mer) et planimétriques, calées dans un repère géographique. Très utilisés en CAO et en synthèse d'images, ils apportent également beaucoup de possibilités pour la réalisation d'analyses paysagères, ou la compréhension de certains risques naturels.

Intégrée dans un système d'information géographique, cette information joue alors un rôle important, à l'instar des courbes de niveau et estompages (ombrages) dans une carte traditionnelle, avec cependant des possibilités d'exploitation bien supérieures, notamment en terme d'analyse spatiale.

Nous disposons d'un MNT de résolution 10m de la même zone d'étude illustré par la figure B.7.



(a): MNT de la zone d'étude

(b) : Visualisation 3D du MNT

Figure B.7. *MNT de la zone d'étude.*

B.2.5 Diversité des espèces

L'étude de l'inventaire forestier fait ressortir un nombre important de strates dans la zone d'étude. La diversité des espèces forestières et l'abondance des classes d'occupation du terrain marquent la spécificité du cadre particulier de la forêt d'où l'importance des choix d'approches et de connaissances pour gérer la confusion entre classes.

B.3 Méthode de mise en œuvre de l'inventaire forestier national

L'inventaire forestier et pastoral national couvre tout le territoire de la Tunisie (la partie des terrains désertiques, quasi désertiques et des grands chotts n'est pas incluse) et utilise pour l'exécution de sa mission un découpage administratif. Le gouvernorat est ainsi l'unité d'inventaire et fait l'objet d'une partition en domaines d'étude cartographiés. Deux inventaires ont été élaborés, le premier a été achevé en 1994 et le deuxième (celui que nous avons utilisé comme source d'informations dans notre travail) a été finalisé en 2005. La classification utilisée dans ce dernier inventaire est basée essentiellement sur l'espèce dominante et sur la distribution et l'importance du couvert ligneux ou herbacé. Les formations forestières ont été classées en unités homogènes en tenant compte de la composition, du recouvrement et du stade de dévolution des peuplements. Les renseignements relatifs aux différents échantillons sont obtenus par interprétation de photographies aériennes, par étude de documents divers, par enquête et par mesures et observations sur le terrain.

En règle générale les travaux de l'inventaire s'exécutent en trois phases :

- La première phase s'effectue par photo interprétation pour délimiter des unités aussi homogènes que possible au regard de l'étude de stratification.
- La deuxième phase a pour objet de vérifier, par observation sur le terrain, les résultats de la première phase et de corriger les éventuelles erreurs.
- La troisième phase a pour objet, au moyen de mesures et observations sur le terrain, d'estimer des caractéristiques dendrométriques ou de phytomasse.

Les photographies aériennes sont en format 23*23 Cm et à l'échelle 1/20.000 sur émulsion infrarouge noir et blanc. Aussi, deux types de produits satellitaires ont été utilisés :

- 205 spatiocartes multispectrales corrigées géographiquement et superposables au découpage Lambert Tunisie
- 68 CCT produit SPOT

Les résultats obtenus par l'inventaire ont un caractère général. Ils se rapportent souvent à une grande région ou à un gouvernorat. De ce fait, et dans le cas de petites régions ou bien pour des zones ne contenant pas un nombre suffisant de placettes, l'emploi de ces données devient risqué.

L'inventaire numérique que nous avons utilisé se présente sous une structure vectorielle formée par des polygones. Chaque polygone se réfère à un code correspondant à une nomenclature qui informe sur la nature de la strate et la classification forestière associée.

B.4 Nomenclature utilisée pour le codage de l'inventaire forestier national

Les strates et les types associés ont été codifiés de telle sorte que les polygones peuvent apparaître soit sous forme de régions décrites en code, soit sous formes de strates ou type d'espèce. L'inventaire 2000 a introduit une nouvelle nomenclature que nous présentons dans la figure B.8 suivante.

Composition de l'Inventaire forestier : polygones, strates...

L'inventaire forestier dont on dispose est en format vectoriel et il est structuré en polygones. Chaque polygone représente une strate ou une facette. Comme le montre la nomenclature utilisée dans la codification des polygones, le code d'un polygone informe sur la strate, sur son type, sur le taux de recouvrement, sur la structure et sur quelques autres particularités de la surface du polygone.

10- SUPERFICIES FORESTIERES		30- AUTRES FORMATIONS FORESTIERES							
11- Forêt de feuillus 12- Forêt de résineux 13- Forêt mixte 14- Maquis arboré 15- Garrigue arborée 16- Boqueteau	17- Superficies provi. déboisées 18- Arboretum 19- Parc national 20- Reserves, ... 21- Jeune peuplement (Hauteur tot.< à 2 m et DBH< 7cm ou âge <10 ans) 22- Plantation des berges, dunes,...	31- Maquis non arboré 32- Garrigue non arborée 33- Plantation d'alignement 34- Brise vents / Haies 35- Zones incendiées 36- Infrastructures (Postes forestiers, pépinières, tranchées P.F, Pistes forestières, Poste de vigie,... 37- Clairières forestières							
↓									
FORMATIONS FORESTIERES ARBOREES		RECOURVREMENT	STRUCTURE	PARTICULARITES	Form. arbustives et Form. Particulières				
01- Acacia cyano. 02- Acacia tortillis 03- Autres acacias 04- Autres pins 05- Caroubier 06- Casouarina 07- Chêne Chermès 08- Chêne liège 09- Chêne vert 10- Chêne zeen 11- Cyprés 12- Eucalyptus 13- Genévriers 14- Oléastre 15- Peupleraie 16- Pin d'alep 17- Pin maritime 18- Pin pignon 19- Tamarix 20- Thuya 21- Acacia+Eu. 22- Acacia+ Pins 23- A.ca.+Pins+Eu. 24- Ch. L.+Ch. Z. 25- Chêne L.+Eucal. 26- Ch.L.+P.mariti.	27- Ch. Liège +P. pignon 28- Chêne liège+mélange de Pin 29- Chêne liège+P. d'alep 30- Eucalyptus+ Pin d'alep 31- Mélange de chênes (CL/ CZ/ CV/CK) 32- Mélange de résineux 33- Mélange de feuillus (Eu./Acacias/ Chen) 34- Pin d'alep+ Chêne vert 35- Pin d'alep+ cyprés 36- Pin d'alep + Cypr.+ Eu 37- Pin d'alep+ Cypr. + Acacias 38- Pin d'alep+ pin pignon 39- Pin d'alep+ Thyua 40- Pin d'alep+Genévriers 41- Pin d'alep + Pin maritime 42- Pin pignon + Eu. 43- Pin d'alep+Euc. +Genevr. 44- Autres espèces 45- Pin+ Chene zeen 46- Mélange Feuillus & Résineux 47- Pin pignon+ Thuya 48- Eucalyptus+Thuya 49- Pin d'alep+ Eucal.+ Thuya 50- Chêne L.+ Thuya 51- Chêne L.+ Acacias 52- Thuya+ Acacias	1- > 75 % 2- 50 à 75% 3- 25 à 50 % 4- 10 à 25 % 5- 5 à 10 %	01- Surface momentanément déboisée 02- Futaie régulière 03- Futaie irrégulière 04- Taillis sous futaie 05- Taillis simple 06- Mélange futaie résineuse et taillis	1. Protection contre l'érosion 2. Érosion forte 3. Surpâturage 4. Incendie 5. Mauvais état sanitaire 6. Reboisement mécanisé 7. Reboisement manuel 8. Néant 9. Naturel	Strate à base de : 50- Arbousier 51- Bruyère 52- Calycotome 53- Câpre 54- Chênes (K/ V) 55- Cistes 56- Genévriers 57- Lentisque 58- Myrthe 59- Oléastre 60- Phyllere 61- Romarin 62- Rhus tripartitum 63- Globulaire 64- Thym 65- Periploca 66- Diss 67- Autres 68- Erinacea 69- Rhamnus				
40- SUPERFICIES NON BOISEES		60- AUTRES SUPERFICIES							
40- TERRES DE PARCOURS		50- TERRES DE CULTURES		60- TERRES ARTIFICIALISEES		70- TERRES INCULTES		80- EAUX ET ZONES HUMIDES	
41- Prairies 411- Prairies naturelles 412- Prairies améliorées 42- Pelouses 43- Plantations Pastorales 44- Parcours steppiques d'alfa 45- Autres parcours steppiques 46- Complexes: Agricul.+steppes 47- Formations Vég. Milieux ripicoles		51- Culture annuelle en sec 52- Arboiculture en sec 53- Terres cultivées en irrigué 54- Oasis 55- zones agricoles hétérogènes 56- Zones agroforestières 57- Jachères		61- Espaces urbains 62- Autres espaces construits(rural, aéroport, zones touristiques, complexe sportifs, usines...) 63. Carrières, mines, décharges,... 64. Espaces verts artificialisés non agri.(Parc Urb, Cimet.)		71.T. improductifs 711. Dunes vives 712. Dunes traitées 713. Escarpement, rocheux, plages 72.Terrains nus (à végétation très claire : Recouv. <à 5 %)		81. Cours et voies d'eau 82. Plans d'eau(Nat./Art.) 83. Zones Hum. Intérieures 84. Zones hum. maritimes	
↓									
Unité photo morp.	Unité de végétation		Recouvrement	Etat de la surf. sol		Particularités			
10. Montagnes 11. Glacis érodés 12. Glacis non érodés 13. Plateau caillouteu 14. Plateau gypseux 15 - Pla. Lim.sableux 16. Plaine sableuse 17. Plaine à sol lourd 18. F. dunaires cort 19. F. dunaires litt 20.. Sebkhass - Chotts 21. Oueds larges 22. Oueds étroits 23. Dépress. fermées 24. Dépress. ouvertes	PARCOURS NATUREL 51. Anabasis aphylla 52. Anabasis oropediolum 53. Anthyllis senecia 54. Aristida pungens 55. Artemisia campestris 56. Artemisia herba alba 57. Arthrop. Schmittiarum. 58. Arthrop. Scoparium 59. Astragalus armatus 60. Calligonum comosum 61. Genista saharae 62. Gymnocarpus decander 63. Hedysarum carnosum 64. Helianthemum kahiricu. 65. Moricandia arvensis 66. Oudneya Africana 67. Periploca laevigata		68. Polygonum équesetifo. 69. Retama retam 70. Rhanterium suaveolens 71. Rosmarinus off. 72. Stipa tenacissima 73. Thymelea hirsuta 74. Thymelea microphylla 75. Traganum nudatum 76. Végétation halophile 77. Végétation cultigène 78. Végétation gypsicole 79. Végétation ripicole 80. Zizyphus lotus	1. 75% 2. 50 à 75 % 3. 25 à 50% 4. 10 à 25 % 5. 5 à 10%	01. Voile éolien discontinu 02. Dunes 03. Pellicule de battance 04. encroûtement calcaire 05. Encroûtement gypseux 06. Sol meuble (sable-limon) 07. Argile, marne 08. Rocheux caillouteux 09. Matière organique (litière)		1. Protection contre l'érosion 2. Erosion forte 3. Surpâturage 4. Incendie 5. Mauvais état sanitaire 6. Mise en défens 7. Plantation d'espèces fourragères 8. Néant		
Exemples de codes utilisés : 13263034- 21372037- 3261- 37- 4410723083- 4720794018- 51- 62- 72- 84									

Figure B.8. Nomenclature utilisée pour l'inventaire forestier national.

ANNEXE C

APPLICATION DE L'ALGORITHME DE CROISSANCE DE REGIONS PAR MOUVEMENT BROWNIEN

Paramétrage de l'algorithme

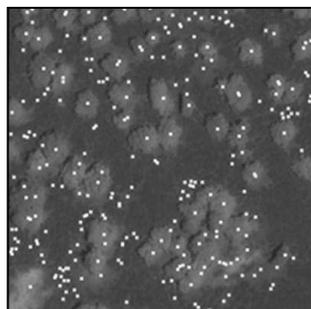
ANNEXE C

Application de l'algorithme de croissance de régions par mouvement Brownien : Paramétrage de l'algorithme

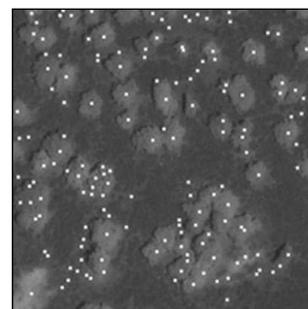
Cet annexe présente le paramétrage de l'algorithme de croissance de régions par mouvement brownien pour la détection des couronnes d'arbres appliqué sur des fenêtres de notre image Quickbird, pour illustration. L'extraction des couronnes par l'algorithme de croissance de régions par mouvement brownien est notée tout au long de cet annexe ECMB.

C.1 Détermination des maximums locaux

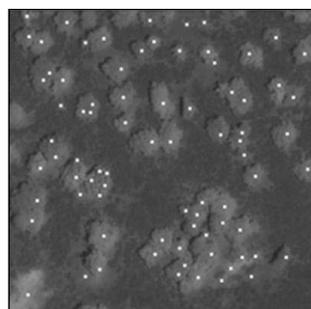
La figure C.1 et la figure C.2 montrent que le choix du masque est primordial pour l'extraction des maximums locaux et qu'il diffère d'une image à l'autre. En effet, pour l'espèce chêne zen caractérisé par des couronnes de vaste étendu, une taille de fenêtre assez grande permet de repérer des maximums locaux qui correspondent aux centres des couronnes. Ceci est illustré par les figures C.1 (c) et C.1 (d), pour lesquelles nous utilisons les masques 11*11 et 13*13.



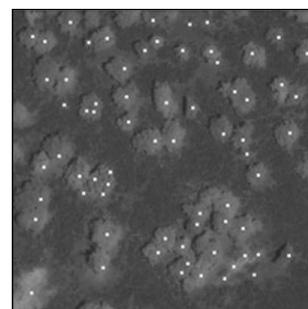
(a) : masque de taille 3*3



(b): masque de taille 5*5



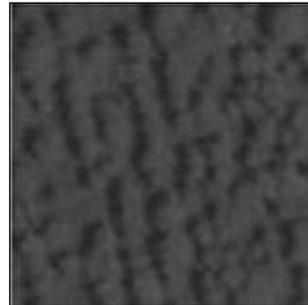
(c) : masque de taille 11*11



(d): masque de taille 13*13

Figure C.1. Extraction des maximums locaux sur une image de l'IHR correspondant à une forêt épaisse avec l'algorithme ECMB pour des masques de différentes tailles.

En effet, les deux figures C.1 (a) et C.1 (b) sont le résultat de l'application d'un masque 3×3 pour la première fenêtre et d'un masque 5×5 pour la deuxième. On remarque dans les deux images une explosion dans le nombre de maximums locaux ce qui va provoquer une surestimation du nombre des couronnes d'arbres. Les points blancs dans l'image représentent les maximums locaux.



(a) : image initiale

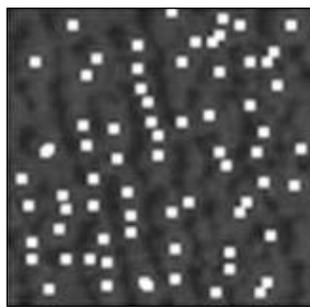
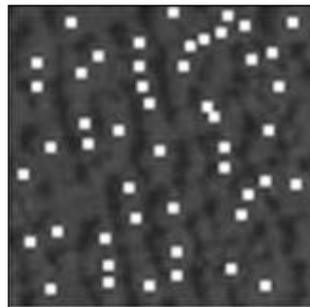
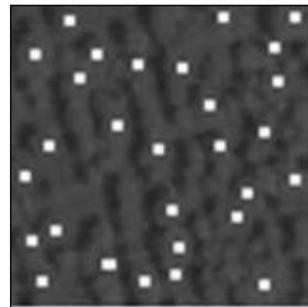
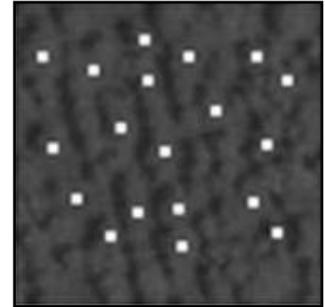
(b) : masque 3×3 (c) : masque 5×5 (d) : masque 11×11 (e) : masque 13×13

Figure C.2. Extraction des maximums locaux sur une image de l'IHR correspondant à une forêt dense avec l'algorithme ECMB pour des masques de différentes tailles.

Pour la figure C.2 (a), c'est un groupement d'arboretum dense. Les deux images C.2(b) et C.2(c) donnent un meilleur résultat et sont dues à l'application d'un masque 3×3 et 5×5 . Pour les images C.2 (d) et C.2 (e), on remarque que beaucoup de sommets d'arbres n'ont pas été détectés.

Le deuxième paramètre qui entre en jeu dans la segmentation est la valeur du seuil. Le rôle de ce seuil est de filtrer les pixels qui ne correspondent pas à des arbres. Ce seuil dépend du canal et de la réflectance spectrale des arbres. La figure C.3 illustre des résultats de segmentation obtenus avec des seuils de 0,5 et de 0,7. L'utilisation d'un seuil faible se traduit par une sur-segmentation faisant apparaître des bruits (fausses couronnes) comme le montre la figure C.3(e). Le seuil à 0,7 aboutit à mieux dégager les couronnes essentielles (figure C.3.(c)).

Le dernier paramètre de l'algorithme CRMB est le nombre de pas du mouvement Brownien. La figure C.4 montre qu'un mauvais choix de ce paramètre provoque une

déformation des couronnes d'arbres. En effet, la figure C.4 (c) montre des couronnes déformées due à une sous estimation du nombre de pas lors de la segmentation de la figure C.4 (a), alors que pour la figure C.4 (b) les couronnes sont très bien détectées. Une sous estimation du nombre de pas provoquera une déformation des couronnes vu que la particule ne va pas atteindre tous les points de la couronne. Une sur estimation quant à elle provoquera la fusion avec certaines couronnes ou bien une déformation de ces dernières. Le choix du seuil se basera alors sur la taille des arbres et sur leur densité.

C.2 Extraction des couronnes d'arbres

Nous présentons le résultat de l'application de l'extraction des couronnes d'arbre sur une fenêtre de l'image QuickBird de notre zone d'étude. Les figures C.5 jusqu'à C.9 représentent le résultat d'extractions des couronnes d'arbres à travers les différentes étapes de l'algorithme ECMB. La figure C.6 représente un groupement d'arbres épars, le résultat est excellent et les arbres sont très bien délimités. La figure C.7 est celle d'un groupement de chêne liège. Les couronnes sont bien extraites mais quelques unes sont un peu déformées. La figure C.8 représente un groupement d'arboretum. La segmentation donne de très bons résultats et les couronnes ne subissent pas de déformation. La Figure C.9 est celle d'un groupement de forêts de résineux et c'est là où on rencontre le plus de problèmes vu qu'il existe des régions qui ont été déformées et d'autres qui ont été fusionnées. Mais le résultat reste acceptable.

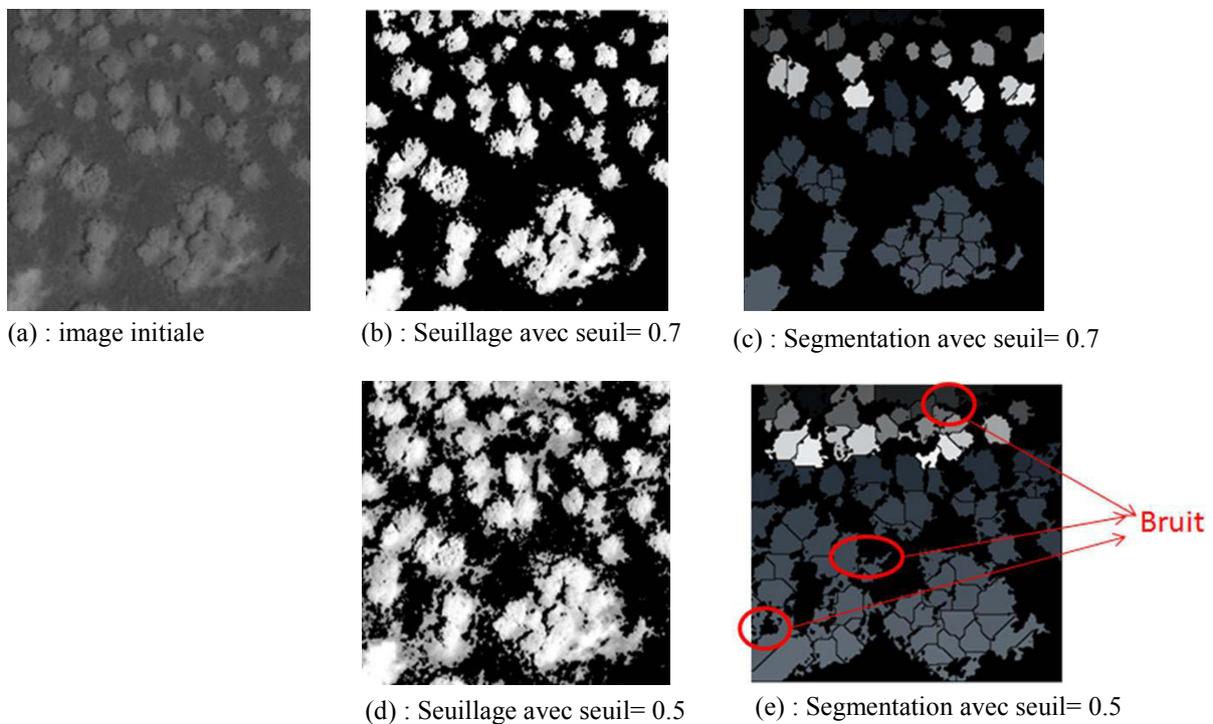


Figure C.3. Résultats de segmentation avec deux seuils différents 0.5 et 0.7.

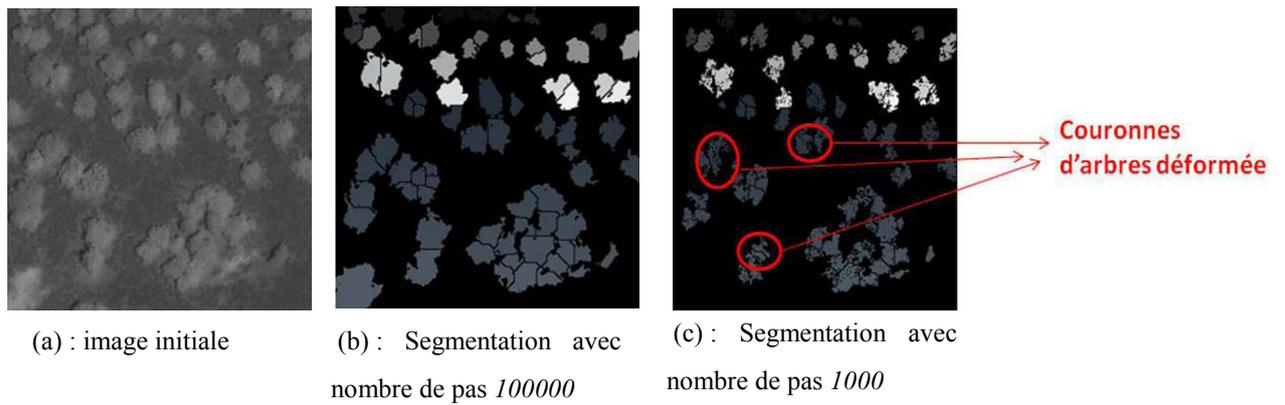


Figure C.4. Segmentation avec deux nombre de pas différents (100000 et 1000).

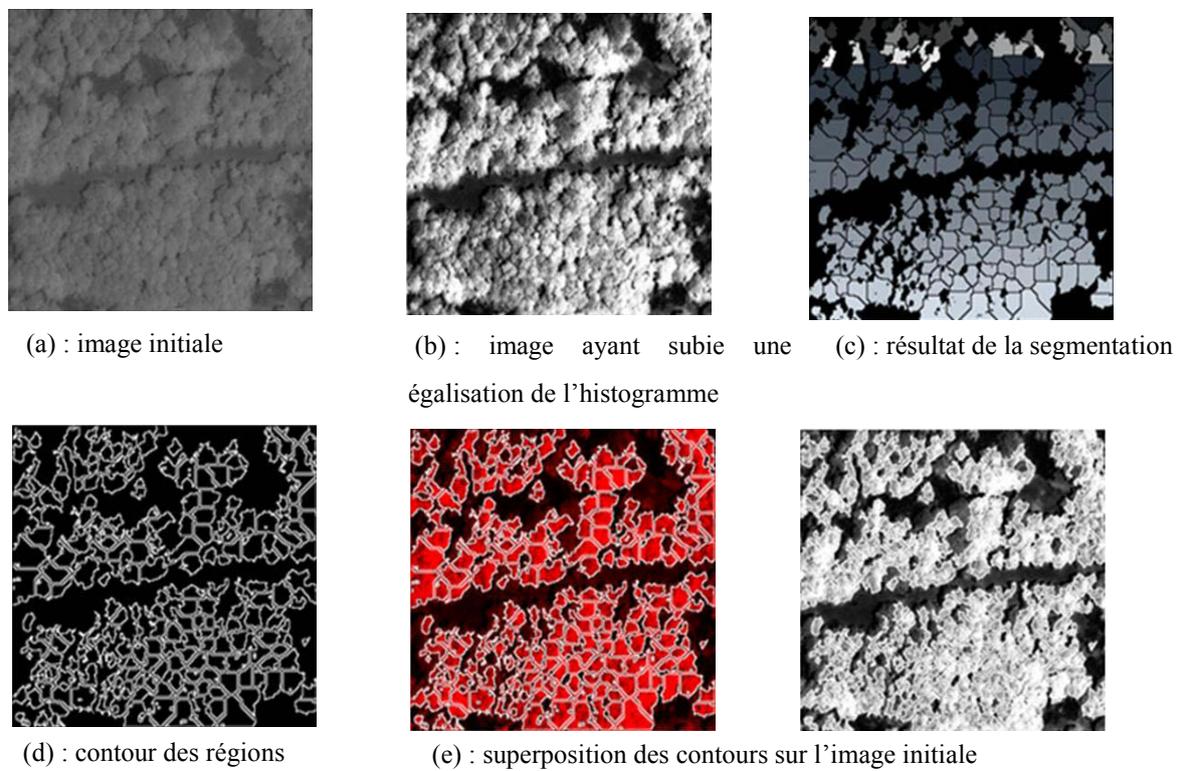
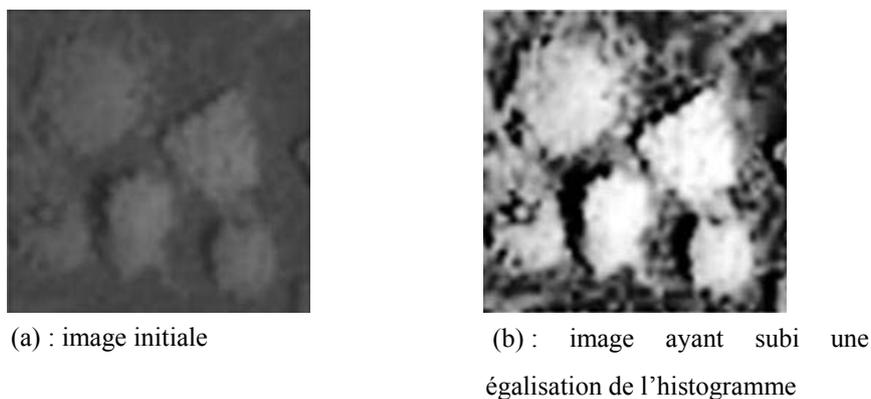
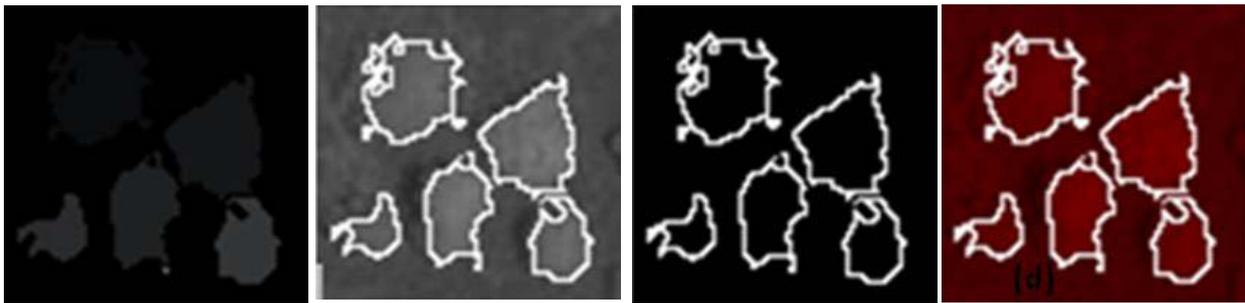


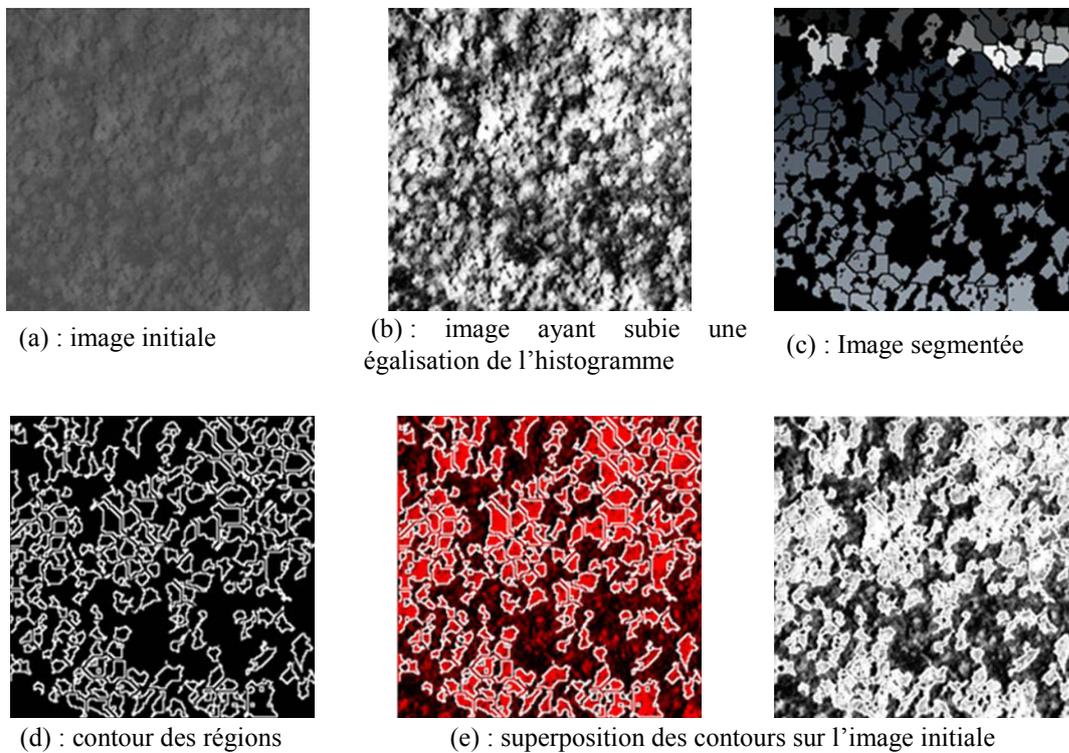
Figure C.5. Segmentation d'un groupement de chêne zen dense.





(c) : Image segmentée (d) : contour des régions (e) : superposition des contours sur l'image initiale

Figure C.6. Segmentation d'un groupement de chêne zen épars.



(a) : image initiale

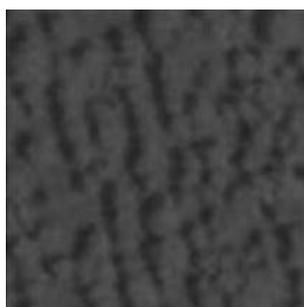
(b) : image ayant subie une égalisation de l'histogramme

(c) : Image segmentée

(d) : contour des régions

(e) : superposition des contours sur l'image initiale

Figure C.7. Segmentation d'un groupement de chêne liège.



(a) : image initiale



(b) : image ayant subie une égalisation de l'histogramme

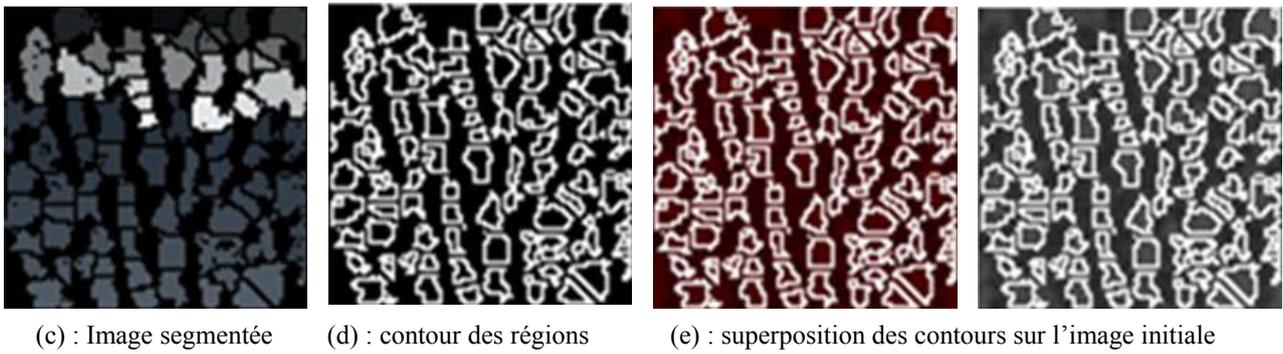


Figure C.8. Segmentation d'un groupement d'arboretum.

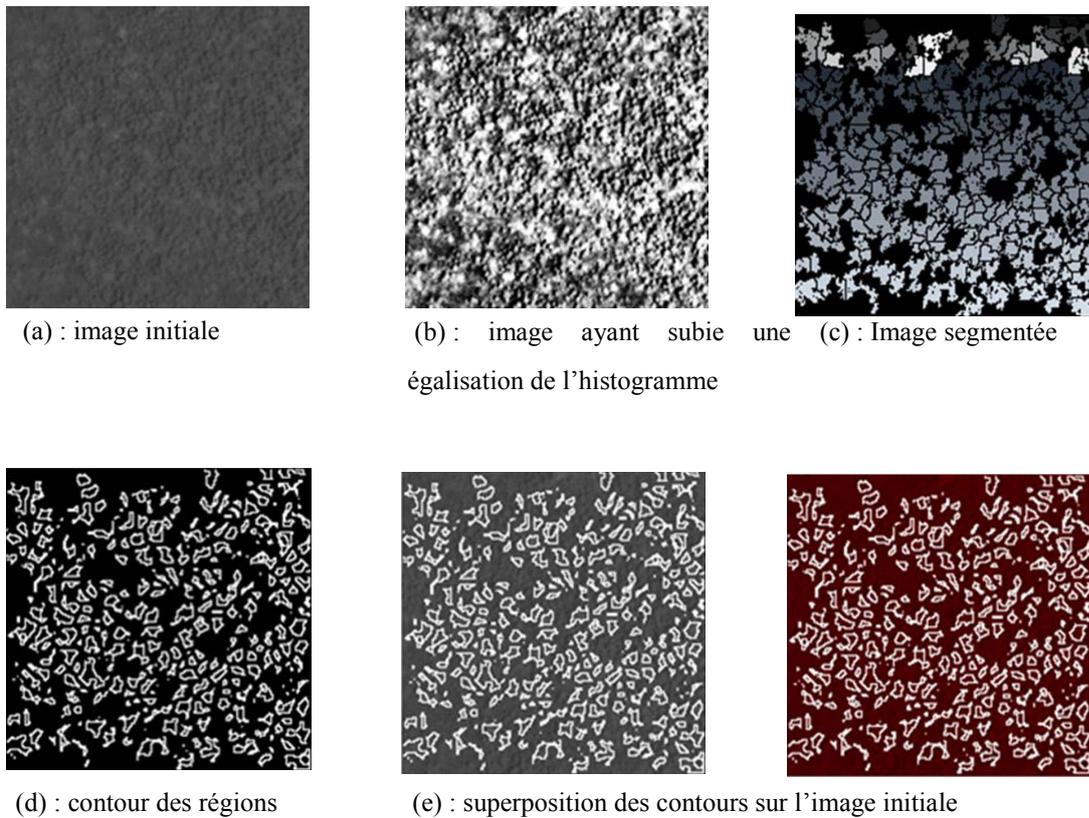


Figure C.9. Segmentation d'un groupement de forêt de résineux.