

THESE

pour obtenir

le grade de DOCTEUR

présentée conjointement

à

l'UNIVERSITE DE SAVOIE

Spécialité : Electronique - Electrotechnique - Automatique

et à

UNIVERSITATEA "POLITEHNICA" BUCUREȘTI

Spécialité : Ingénierie Electronique et Télécommunications

par

M. Florentin BUJOR

*Extraction - fusion d'informations
en imagerie radar multi-temporelle.*

Soutenue le 26 juillet 2004 devant le jury d'examen :

M. Corneliu BURILEANU	Président
M. Jean-Marie BECKER	Rapporteur
M. Alexandru ȘERBĂNESCU	Rapporteur
M. Vasile BUZULOIU	Directeur de thèse
M. Philippe BOLON	Directeur de thèse
M. Emmanuel TROUVÉ	Co-Directeur de thèse

Remerciements

L'ensemble des travaux présentés dans ce mémoire ont été effectués dans deux laboratoires de recherche, à savoir le Laboratoire d'Informatique, Systèmes, Traitement de l'Information et de la Connaissance (LISTIC) de l'Université de Savoie et le Laboratoire d'Analyse et Traitement d'Images (LAPI) de l'Université "Politehnica" de București.

Je tiens à remercier Monsieur Philippe Bolon, Professeur à l'Université de Savoie, directeur du LISTIC, pour m'avoir accueilli au sein de son laboratoire.

Je tiens à exprimer ma profonde gratitude à Monsieur Vasile Buzuloiu, Professeur à l'Université "Politehnica" de București, directeur du LAPI, pour la chance qu'il m'a donnée en me prenant dans son équipe de recherche.

J'exprime aussi mes sincères remerciements à Monsieur Jean-Marie Becker, Professeur à l'École Supérieure Chimie Physique Electronique de Lyon (CPE-Lyon), et à Monsieur Alexandru Șerbănescu, Professeur à l'Académie Technique Militaire de București, pour l'intérêt qu'ils ont porté à cette thèse, en acceptant de l'examiner et d'en être rapporteurs. Je remercie également Monsieur Corneliu Burileanu, Vice-Doyen de la Faculté d'Electronique et Télécommunications de l'Université "Politehnica" de București, d'avoir accepté de présider le jury d'examen.

Je tiens à exprimer ma gratitude envers mes directeurs de thèse : Monsieur Emmanuel Trouvé, Maître de Conférences à l'Université de Savoie, Monsieur le Professeur Philippe Bolon, et M. le Professeur Vasile Buzuloiu, pour la confiance qu'ils m'ont témoignée. Leur expérience de recherche, leurs conseils, leurs encouragements m'ont été très précieux et m'ont permis de mener à bien mon travail.

Je remercie également tous les membres du LISTIC et du LAPI pour l'atmosphère chaleureuse et accueillante existante dans les deux établissements de recherche.

Enfin, je remercie toute ma famille et mes amis qui m'ont soutenu tout au long de ce travail.

Table des matières

Remerciements	3
Table des matières	i
Liste des tableaux	vii
Liste des figures	ix
Abréviations - Notations	xv
1 Introduction générale	1
I Etat de l'Art et Données Expérimentales	7
2 Analyse d'images RSO multi-temporelles	9
2.1 Télédétection multi-temporelle	10
2.1.1 Types de capteurs et de données	10
2.1.2 Données optiques	11
2.1.3 Données radar	12
2.1.4 Information complémentaire	17
2.2 Détection de changements	19
2.2.1 Approches	19
2.2.2 Applications	25
2.3 Conclusions	27
3 Données RSO multi-temporelles	29
3.1 Région de Saint-Laurent du Maroni	29

3.1.1	Site	30
3.1.2	Données	30
3.2	Région de Kourou	32
3.2.1	Site	33
3.2.2	Données	33
3.3	Région de Douala, Cameroun	35
3.3.1	Site	35
3.3.2	Données	36
II Extraction - Fusion d'Informations		39
4	Opérateurs d'extraction d'informations	41
4.1	Attributs dédiés aux structures ponctuelles	42
4.1.1	Données mono-date : détecteur de points brillants	42
4.1.2	Données multi-dates : différence de points brillants	44
4.1.3	Utilisation et résultats	45
4.2	Attributs dédiés aux structures linéaires	46
4.2.1	Données mono-date : détecteur de contours	46
4.2.2	Données mono-date : détecteur de lignes	48
4.2.3	Données multi-dates : différence de contours	50
4.2.4	Données multi-dates : détecteur de contours multi-temporels (DCMT)	52
4.2.5	Évaluation des performances	53
4.3	Attributs relatifs aux surfaces	55
4.3.1	Données bi-temporelles : détecteur de changements bi-temporels (DChBT)	55
4.3.2	Données multi-temporelles : détecteur de changements multi-temporels (DChMT)	55
4.3.3	Évaluation des performances	56
4.4	Attributs relatifs aux textures	57
4.4.1	Statistiques de deuxième espèce	58
4.4.2	Fonctions caractéristiques de deuxième espèce	59
4.4.3	Calcul des attributs dédiés aux textures	60
4.4.4	Évaluation des performances	65
4.5	Conclusions	67

5	Fusion d'informations	71
5.1	Intérêts de la fusion d'informations	72
5.1.1	Fusion d'informations dans le contexte image	72
5.1.2	Techniques classiques de combinaison pour la fusion d'information	73
5.2	Fusion/classification	75
5.2.1	Classification non-supervisée	76
5.2.2	Classification supervisée	76
5.3	Fusion floue interactive d'attributs	77
5.3.1	Description linguistique	78
5.3.2	Pondération des règles	82
5.3.3	Interface Homme Machine	84
5.4	Conclusion	86
6	Applications	89
6.1	Détection de changements bi-temporels	90
6.1.1	Attributs	91
6.1.2	Fusion	92
6.1.3	Résultats	95
6.1.4	Conclusion	98
6.2	Détection de structures spatiales stables	99
6.2.1	Fusion de détections vs. détection mono-temporelle	99
6.2.2	Comparaison entre différents formats de données	103
6.2.3	Conclusion	104
6.3	Détection simultanée de structures spatio-temporelles	106
6.3.1	Attributs	107
6.3.2	Fusion	108
6.3.3	Résultats	108
6.3.4	Conclusion	111
6.4	Bilan	112
7	Conclusions et perspectives	113

III	Annexes	119
A	Principes de l'imagerie RSO	121
A.1	Imagerie RSO	121
A.2	Principes de formation de l'image RSO	123
A.2.1	Déformations	125
A.3	Propriétés du signal RSO	127
A.3.1	Intensité	127
A.3.2	Propriétés du speckle	128
B	Illustration des images RSO	
	multi-temporelles et des données complémentaires	131
B.1	Région de Saint-Laurent du Maroni	132
B.2	Région de Kourou	140
B.3	Région de Douala	147
C	Annexe technique :	
	Interface <i>Fusion Floue Symbolique</i>	149
C.1	Fenêtre principale	149
C.1.1	Barre de menus	150
C.2	Fenêtres de visualisation/représentation	153
C.2.1	Fenêtre de visualisation d'images originales	154
C.2.2	Fenêtres de visualisation d'images d'attribut	154
C.2.3	Fenêtre de visualisation des résultats	154
C.2.4	Fenêtre de représentation de règles 2D	156
C.2.5	Fenêtre de représentation de règles 3D	157
C.3	Fonctionnement de l'IHM	159
D	Classification non-supervisée : C-moyennes floues	161
D.1	L'algorithme des C-moyennes floues	161
D.2	Application aux images multi-composantes	164
E	Classification supervisée :	
	Machines à Vecteurs de Support	165
E.1	Machines à vecteurs de support (SVM)	165

E.1.1	Principe des SVM	166
E.1.2	Recherche de l'hyperplan séparateur optimal	166
E.1.3	Fonction noyau	167
E.1.4	Exemple de fonction noyau	168
E.2	Application des SVM à la classification d'images	168
F	Évaluation des performances	171
F.1	Matrice de confusion	171
	Bibliographie	175
	Publications de l'auteur	183

Liste des tableaux

2.1	Bandes de fréquence disponibles pour les systèmes RSO	13
2.2	Les caractéristiques des systèmes RSO satellitaires	14
2.3	Les programmes SIR	14
3.1	Série Saint-Laurent du Maroni, données RSO multi-temporelles acquises par les satellites ERS-1 et ERS-2, Frame 3501, orbites descendantes.	32
3.2	Série Kourou, données RSO multi-temporelles acquises par le satellite ERS-1, Frame 3501, orbites descendantes.	34
3.3	Série Douala, données RSO multi-temporelles.	37
4.1	Méthode de codage pour des attributs avec une dynamique symétrique ou quasi-symétrique.	45
6.1	Matrice de confusion pour le résultat obtenu avec la méthode de fusion floue interactive : SSS - Structures Spatiales Stables ; CT - Changements Temporels ; RH - Régions Homogènes.	111
6.2	Matrice de confusion pour le résultat obtenu avec la méthode de classification non-supervisée (FCM).	111
6.3	Matrice de confusion pour le résultat obtenu avec la méthode de classification supervisée (SVM).	112
F.1	Exemple de matrice de confusion.	172

Liste des figures

3.1	Carte de la région de Saint-Laurent du Maroni (extrait de la carte fig. B.1, échelle 1 : 500 000 ©IGN).	30
3.2	La zone de rizières de la série Saint-Laurent du Maroni, images 512×512 extraites des présentées fig. B.4, annexe B.	31
3.3	Masques pour l'évaluation de performances ; gris : masque de fausse alarme, M_{fa} ; noir : masque de détection, M_d , correspondant aux zones d'abattis.	32
3.4	Extrait de la carte de région de Kourou ©IGN.	33
3.5	Extraits des trois images (1,4,7 ; tab. 3.2) des la série des données multi-temporelles de la zone de Kourou, Guyane française (fig. B.11 en annexe B.	34
3.6	Vérité terrain pour la région du Kourou : bleu - zones de changements temporels ; rouge - zones avec des structures spatiales stables ; blanc - zones homogènes de point du vue spatial et temporel.	35
3.7	Extrait de la carte de la région de Douala, Cameroun.	36
3.8	Extraits de la série de la région Douala : (a) orbite montante ; (b) orbite descendante.	36
4.1	Images contenant des informations ponctuelles (a,b), résultats du détecteur de points brillants (c,d) et de la différence de point brillants (e).	47
4.2	Exemples des voisinages utilisés pour la détection de contours.	48
4.3	Codage des orientations.	48
4.4	Détection de contours sur une image de la série de la région de Saint-Laurent du Maroni, Guyane française.	49
4.5	Forme de détecteurs de lignes.	50
4.6	Détection de structures fines : (a) image ERS de la région de Douala, Cameroun ; (b) image résultat du détecteur de lignes dl éq. (4.17).	51

4.7	Différence de contours sur des images de la série Saint-Laurent du Maroni, Guyane française : noir - valeurs négatives, blanc - valeurs positives.	52
4.8	Résultat du détecteur de contours multi-temporels appliqué sur la série Kourou.	53
4.9	Evaluation des performances pour le détecteur de contours multi-temporels (DCMT).	54
4.10	Résultat du détecteur de changements bi-temporels appliqué à une paire d'images de la série Saint-Laurent du Maroni, Guyane française.	56
4.11	Résultat du détecteur de changements multi-temporels appliqué sur la série de données Kourou.	57
4.12	Evaluation des performances pour le détecteur de changements multi-temporels (DChMT).	58
4.13	Résultats des paramètres de texture estimés pour la série de Kourou : (a) log-cumulant du deuxième ordre $\widehat{\kappa}_2$, (b) log-cumulant du troisième ordre $\widehat{\kappa}_3$.	62
4.14	Valeurs théoriques $(\tilde{\kappa}_3, \tilde{\kappa}_2)$ pour un mélange binaire de distributions Gamma donné Eq. (4.41), $L = 3$, λ variant dans l'intervalle $[0, 1]$	63
4.15	Résultat du paramètre de texture λ (niveau de mélange de deux distributions Gamma) estimé pour la série de Kourou.	64
4.16	Densités de probabilité conditionnelle (d.d.p.c.) des paramètres de texture, calculés avec les 3 ensembles des régions de référence (SSS : structures spatiales stables, CT : changements temporels, et RH : régions homogènes).	66
4.17	Evaluation des performances pour les paramètres de texture.	67
4.18	Comparaison de la sensibilité aux structures spatiales (dessus) et aux changements temporels (dessous) des attributs proposés (DCMT, DChMT et $\widehat{\kappa}_2$) et du Test de Vraisemblance Généralisée.	69
5.1	Principe d'un système de fusion floue coopératif appliqué à la détection de changements.	79
5.2	Exemple de partition floue associée à un attribut A_1	80
5.3	Exemple de Tableau de règles pour la fusion de deux attributs de type "détecteur de route".	81
5.4	Cellules d'intégration d'un histogramme 2D correspondant à une partition floue.	83
5.5	Interface graphique.	84

5.6	Exemple de nuages de points correspondants aux histogrammes 2D qui facilitent l'ajustement des fonctions d'appartenance pour deux attributs (distance et DChBT).	85
5.7	Résultat de fusion "3 classes" sans réglage fin : degrés d'appartenance aux 2 classes recherchées et à la classe de rejet	86
5.8	Réglage fin des règles et des fonctions d'appartenance de la figure 5.6.	87
5.9	Résultats de fusion "3 classes : (a) avant ajustement fin ; (b) après ajustement.	87
6.1	Information a priori : a) carte ; b) attribut "distance aux routes".	90
6.2	Attributs de changement : a) attribut DChBT ; b) valeur du critère χ^2	91
6.3	Partitions floues des attributs <i>distance aux routes</i> et DChBT.	93
6.4	Interface Homme-Machine.	94
6.5	Résultats de détection de changements de type <i>abattis</i> obtenus par fusion de 2 attributs à l'échelle microscopique (a), à l'échelle macroscopique (b) et par fusion de 3 attributs (c).	95
6.6	Evaluation des performances par courbes COR ; ligne continue : avant ajustement (fig. 5.9-a) ; ligne pointillée : après ajustement (fig. 5.9-b).	97
6.7	Evaluation des performances par courbes COR ; ligne continue : fusion de deux attributs (fig. 6.5-a) ; ligne pointillée : fusion de trois attributs (fig. 6.5-c).	98
6.8	Images 16 bit acquises en orbite descendante : (a) image ERS-1, 4 décembre 1995 (orbite 22941, frame 3519) ; (b) image ERS-2, 2 février 1999 (orbite 19801, frame 3519).	99
6.9	Sortie de l'opérateur de détection de lignes (a) image ERS-1 et (b) image ERS-2.	100
6.10	Zones de référence issues de vérité terrain. Portion de route en blanc, zone sans route en gris : (a) Masque d'apprentissage des régions <i>route</i> et <i>pas route</i> ; (b) masque d'évaluation des performances.	100
6.11	Fusion des résultats du détecteur de lignes dans les images ERS-1 et ERS-2.	101
6.12	Histogramme 2D des résultats de détecteur de lignes sur les images ERS-1 et ERS-2.	101
6.13	Résultats de la fusion de détections de lignes dans les images ERS-1 et ERS-2 : (a) fusion interactive, (b) fusion semi-supervisée.	102
6.14	Evaluation des performances par courbes ROC pour la détection de structures linéaires : ERS-1, ERS-2, fusion interactive, fusion semi-supervisée.	102

6.15	Images 8 bit acquises sur des orbites descendantes et recalées N–S : (a) image ERS-1, (b) image ERS-2.	103
6.16	Images de sortie de l’opérateur de détection de lignes : (a) image ERS1- et (b) Image ERS-2.	104
6.17	Courbes COR pour la fusion de la réponse du détecteur de lignes dans les images ERS-1 et ERS-2, géocodées 8 bits.	105
6.18	Images 8 bit recalées N–S : (a) image ERS-1 — orbite ascendante, (b) image ERS-1 — orbite descendante.	106
6.19	Résultats du détecteur de lignes dans les images (a) ERS-1 — orbite ascendante, et (b) ERS-1 — orbite descendante.	106
6.20	Evaluation des performances par courbes COR. Images recalées, géocodées et quantifiées.	107
6.21	Comparaison des performances de l’opérateur de fusion en fonction du type d’images traitées.	108
6.22	Images d’attribut : (a) DCMT ; (b) DChMT ; (c) le log-cumulant d’ordre 2 $\tilde{\kappa}_2$. 109	
6.23	Comparaison des résultats de classification, noir : SSS, gris : CT, blanc : RH. 110	
A.1	Acquisition des images RSO.	122
A.2	La compression en avant.	125
A.3	Le repliement.	126
A.4	L’ombrage.	126
A.5	Angles d’incidence.	127
B.1	Carte de la région Saint-Laurent du Maroni, échelle 1 : 500 000 ©IGN. . .	132
B.2	Données multi-temporelles ERS-1 et ERS-2 sur la Guyane française, images 2300 × 2400 : (a) 6 mai 1992 ; (b) 10 juin 1992.	133
B.3	Données multi-temporelles ERS-1 et ERS-2 sur la Guyane française, images 2300 × 2400 (cont.) : (a) 12 décembre 1992 ; (b) 26 mai 1993.	134
B.4	Données multi-temporelles ERS-1 et ERS-2 sur la Guyane française, images 2300 × 2400 (cont.) : (a) 30 juin 1993 ; (b) 15 novembre 1997.	135
B.5	Carte de la région de Ssaint-Laurent du Maroni, avec le réseau de routier et les données RSO en fond de carte, ©UMLV.	136
B.6	Incrustation des photographies aériennes de 1991 et 1999 sur la carte précédente (fig. B.5).	137
B.7	Photographie aérienne (numérisée) des abattis Guyane française, 1999. . .	138

B.8	Données multi-temporelles de la zone de Kourou, Guyane française.	140
B.9	Données multi-temporelles de la zone de Kourou, Guyane française (cont.).	141
B.10	Données multi-temporelles de la zone de Kourou, Guyane française (cont.).	142
B.11	Données multi-temporelles de la zone de Kourou, Guyane française (cont.).	143
B.12	Carte de la région de Kourou ©IGN.	144
B.13	Carte de la végétation entre Kourou et le Centre Spatial Guyanais.	145
B.14	Vérité terrain pour la région du Kourou : bleu - zones de changements temporels ; rouge - zones de structures spatiales stables ; blanc - zones homogènes de point de vue spatial et temporel.	146
B.15	Série de la région Douala : (a) 23 Août 1994, orbite montante; (b) 4 Décembre 1995, orbite descendante; (c) 2 Février 1999, orbite descendante.	147
B.16	Carte de la région de Douala, Cameroun ©IGN.	148
C.1	Fenêtre de démarrage de l'IHM <i>Fusion Floue Symbolique</i>	150
C.2	Menu File	150
C.3	Menu Tuning	151
C.4	Sous-menu Processing → Region Of Interest	151
C.5	Fenêtre pour la manipulation de régions d'intérêt.	151
C.6	Sous-menu Processing → Histograms	152
C.7	Sous-menu Processing → Fusion	152
C.8	Menu Evaluation	153
C.9	Matrice de confusion.	153
C.10	Menu Display	153
C.11	Fenêtres de visualisation d'images originales (image RSO en niveaux de gris) et de sélection de régions d'intérêt (marque de classes en couleur).	154
C.12	Fenêtre de visualisation d'images d'attribut.	155
C.13	Visualisation du résultat de fusion.	155
C.14	Représentation de règles 2D.	156
C.15	Exemple d'ajustement de règles 2D.	157
C.16	Fenêtre de représentation de règles 3D.	158
C.17	Exemple d'ajustement de règles 3D.	158
E.1	Exemple de sur-apprentissage (classifieur de haut degré - rouge) et sous-apprentissage (classifieur linéaire - vert) par rapport à un apprentissage optimal (bleu).	166

E.2 Principe des SVM. 167

Abréviations - Notations

<i>COR</i>	Caractéristiques Opérationnelles du Récepteur
<i>CT</i>	Changements Temporels
<i>DCMT</i>	Détecteur de Contours Multi-Temporels
<i>DChBT</i>	Détecteur de Changements Bi-Temporels
<i>DChMT</i>	Détecteur de Changements Multi-Temporels
<i>d.d.p.</i>	densité de probabilité
<i>d.d.p.c.</i>	densité de probabilité conditionnelle
<i>ERS</i>	European Remote Sensing (satellites ERS-1 et ERS-2)
<i>FCM</i>	Fuzzy C-Means (C-moyennes floues ; méthode de classification non-supervisée)
<i>N</i>	Nombre d'images d'une série multi-temporelle
<i>NbA</i>	Nombre d'attributs
<i>NbC</i>	Nombre de classes
<i>NbE</i>	Nombre d'échantillons

<i>NbP</i>	Nombre de points
<i>RH</i>	Régions Homogènes
<i>PRI</i>	PRécision Image (format d'images RSO, amplitude codée sur 16 bits)
<i>RSO</i>	Radar à Synthèse d'Ouverture
<i>SIG</i>	Systèmes d'Information Géographique
<i>SSS</i>	Structures Spatiales Stables
<i>SVM</i>	Support Vecteur Machines (méthode de classification supervisée)
<i>TVG</i>	Test de Vraisemblance Généralisée

Chapitre 1

Introduction générale

Les développements méthodologiques dédiés à l'analyse des données satellitaires multi-temporelles sont aujourd'hui un enjeu crucial pour la communauté de la télédétection. Ce besoin est lié d'une part à l'accumulation de données acquises depuis plusieurs décennies en imagerie optique et bientôt 20 ans en imagerie radar, et d'autre part au nombre sans cesse croissant de satellites d'observation de la terre en activité ou sur le point d'être lancés. La télédétection optique est souvent préférée en raison de la facilité d'analyse et de traitement des images acquises dans différentes bandes spectrales (visible, infra-rouge, etc.). Les capteurs utilisés ont une perception proche de celle de l'œil humain en terme de géométrie et de radiométrie. L'inconvénient de la télédétection optique est que les capteurs utilisés sont passifs et donc dépendants du rayonnement solaire et des conditions météorologiques. En revanche, la télédétection radar garantit l'observabilité des régions étudiées, faisant des images radar à synthèse d'ouverture (RSO) une source privilégiée d'informations multi-temporelles.

Ces données restent cependant fortement sous-exploitées car, malgré de nombreux travaux réalisés dans le domaine du traitement du signal et des images, la communauté utilisatrice (des laboratoires de géosciences aux organismes en charge de la surveillance et de l'aménagement du territoire) reste réticente quant à une exploitation opérationnelle de ces images. Deux phénomènes liés à l'imagerie RSO sont à l'origine de ces réticences : d'une part le chatoiement (ou speckle) qui affecte la radiométrie des images et apparaît comme un bruit multiplicatif, d'autre part la géométrie radar qui modifie l'échantillonnage au sol des zones de relief. Bien que pouvant être source d'information pour certaines applications, ces phénomènes sont souvent perçus par les utilisateurs potentiels comme des défauts rédhibitoires. Beaucoup sont convaincus que ces images contiennent une informa-

tion utile pour leurs applications mais se trouvent démunis pour appliquer un ensemble de traitements permettant de l'extraire et la restituer sous une forme exploitable. Dans ce contexte, ces travaux de thèse ont pour objectif d'apporter un nouveau maillon à la chaîne de traitement de l'information permettant de passer des données RSO satellitaires multi-temporelles à une information de nature géophysique.

L'information susceptible d'être extraite de ces données donne lieu à deux grandes directions de recherches méthodologiques. La première direction considère les images multi-temporelles comme des données vectorielles où les différentes dates correspondent à différentes bandes analogues à celles de données optiques multi-spectrales. L'analyse des données multi-temporelles consiste alors à développer ou appliquer des méthode de type "classification" pour en déduire l'appartenance des pixels à différentes classes liées à l'occupation des sols (types de forêt, de culture, etc.).

La seconde direction considère les données RSO multi-temporelles comme un ensemble de données tridimensionnelles (3D) avec deux axes correspondant au domaine spatial conventionnel et un troisième axe correspondant à la direction temporelle. La plupart des informations recherchées sont alors situées dans des zones de transitions où le contraste radiométrique et les textures 3D sont significatifs de changements temporels ou de présence de structures spatiales. Nos travaux s'inscrivent dans cette direction, en cherchant à exploiter soit les différences entre dates pour détecter les changements temporels, soit la redondance de l'information pour améliorer la détection de structures spatiales stables.

Les *changements temporels (CT)* correspondent aux changements physiques ayant lieu sur la surface terrestre observables dans les variations du coefficient de rétrodiffusion RSO. Deux sortes de changements peuvent être observés :

- les changements "abrupts (ou en échelon)" correspondant à une forte modification de la surface terrestre imagée survenue entre deux dates d'acquisition. De tels changements apparaissent par exemple dans le cas des déforestations ou des désastres, comme les incendies ou les inondations. Dans ce cas, la détection de changements peut être considérée comme une "détection de contours" dans la direction temporelle.
- les transitions "lentes" correspondant à une évolution moins rapide de la surface terrestre. De tels changements apparaissent dans les régions instables, par exemple le long d'une côte en érosion ou dans les régions agricoles pendant la période de croissance des cultures. Dans ce cas, il n'y a pas un fort contraste entre images et

le problème peut être vu comme une détection d'hétérogénéités dans la direction temporelle.

Les *structures spatiales stables (SSS)* correspondent aux structures ponctuelles comme les bâtiments, aux structures linéaires comme les routes ou les rivières fines, et aux frontières des objets surfaciques comme les lacs, les rivières larges, etc. Ces structures introduisent des discontinuités spatiales qui sont difficilement détectables en présence de speckle lorsqu'une seule image est disponible. Les données RSO multi-temporelles sont utiles pour améliorer leur détection. Lorsque les structures spatiales sont temporellement instables, du fait du déplacement de leurs frontières ou de leur absence dans certaines images, elles peuvent appartenir aux deux classes d'intérêt : SSS ou CT. Puisque leur détection comme structures spatiales peut changer en position ou en contraste, de telles structures spatiales instables seront considérées comme régions de changements.

Pour détecter ces deux principaux ensembles de structures, nous proposons une approche en deux étapes intitulée "extraction-fusion". Ces deux étapes s'imposent par la complexité des données RSO initiales qui rendent infructueuses la plupart des approches directes de type segmentation (2D ou 3D) ou de type détection de structures s'appuyant sur un seul détecteur. De plus, ce choix est guidé par le positionnement de ces travaux dans un contexte d'aide à l'utilisateur à la différence de travaux qui visent à développer des méthodes entièrement automatiques. En choisissant une stratégie en deux étapes, il devient possible de rechercher dans un premier temps des traitements relativement "automatiques" qui fournissent des mesures, appelées attributs, révélatrices de la présence de discontinuités spatio-temporelles. Sauf lorsqu'ils sont optimisés pour une application spécifique, en général et difficilement transposable à d'autres situations, les attributs d'utilisation générique fournissent le plus souvent un résultat qui n'est pas directement exploitable. L'étape de fusion permet d'introduire dans un deuxième temps la connaissance de l'expert ou de l'utilisateur spécialiste de son domaine d'application. L'objectif est alors de fournir à ce dernier les moyens de sélectionner et de combiner de façon interactive les mesures pertinentes pour obtenir le résultat recherché. La mise en œuvre de la première étape s'appuie sur des méthodes relativement classiques en traitement d'images RSO 2D, que nous étendons à l'extraction d'informations dans les données multi-temporelles. La mise en œuvre de la seconde étape s'appuie sur les méthodes de fusion développées au LISTIC fondées sur la théorie des sous-ensembles flous. Nous proposons une implantation sous la forme d'une interface graphique qui réponde aux besoins spécifiques d'une fusion interactive d'attributs issus des images

RSO ou d'informations a priori telles que des cartes, en vue de la détection/classification d'objets géographiques.

L'ensemble de la chaîne de traitement a pu être testé sur des données réelles (images RSO multi-temporelles acquises par les satellites ERS) dans le cadre d'une collaboration étroite avec l'Institut Francilien de Géosciences (Université de Marne-la-Vallée). L'équipe du Professeur Rudant (Laboratoire Géomatériaux), qui nous a fourni ces données, travaille sur la mise à jour de cartes géographiques et sur la surveillance de régions tropicales par télédétection. Leur connaissance de l'imagerie radar et des zones étudiées a permis d'une part de définir les structures recherchées et les informations qui les caractérisent et d'autre part de valider les résultats d'un point de vue qualitatif, les critères de qualité subjectifs de *l'utilisateur* n'étant pas forcément les mêmes que ceux du *concepteur* ! Au delà des méthodes qui constituent les briques de base du traitement des données RSO et de la fusion, cette collaboration a permis de mettre en œuvre la méthodologie de traitement proposée et de tester son adéquation avec les besoins et la démarche de l'utilisateur.

Ce manuscrit est organisé en deux parties complétées par des annexes. La première partie composée des chapitres 2 et 3 introduit le contexte de la télédétection par imagerie satellitaire multi-temporelle. La deuxième partie composée des chapitres 4, 5 et 6 présente les méthodes développées pour les étapes d'extraction et de fusion d'information, puis l'application de l'approche proposées "extraction-fusion" sur trois jeux de données multi-temporelles. Les conclusions et les perspectives de ce travail de thèse font l'objet du chapitre 7.

Le chapitre 2 décrit le contexte de l'analyse d'images RSO multi-temporelles. Dans la première partie de ce chapitre, nous passons en revue la télédétection multi-temporelle en général, en rappelant les spécificités des différents types de capteurs et des données produites. Les applications d'analyse d'images en télédétection sont brièvement abordées. Nous présentons ensuite la détection de changements, avec un survol des méthodes existantes pour les données optiques aussi que des différents domaines d'application. Ce chapitre est complété par l'annexe A qui rappelle les principes de l'imagerie radar à synthèse d'ouverture (RSO) et les caractéristiques essentielles de ces données.

Le chapitre 3 permet d'illustrer le potentiel de l'imagerie RSO multi-temporelle en présentant les données qui sont utilisées dans chacun des chapitres de la seconde partie. Les trois séries d'images RSO multi-temporelles sont présentées avec les informations relatives aux sites géographiques étudiés et aux caractéristiques des données. Une illustration plus

étendue de ces données est proposée en annexe **B**.

La deuxième partie dédiée aux développements méthodologiques commence avec le chapitre **4**. Des opérateurs d'extraction d'informations sont proposés pour les principales primitives structurales présentes dans les images : points, lignes, surfaces ou textures. Le calcul d'attributs révélateurs de ces primitives est fait sur différentes combinaisons d'images multi-temporelles : une seule image, des paires d'images, ou toute la série multi-temporelle. Une méthode d'évaluation de performances est proposée.

Le chapitre **5** introduit le contexte de la fusion d'informations afin de positionner nos travaux. Nous développons ensuite les principes et la mise en œuvre de la méthode de fusion floue interactive proposée pour combiner les attributs obtenus avec les opérateurs d'extraction d'informations présentés au chapitre **4**. Une annexe technique (annexe **C**) fournit des informations détaillées sur les différentes fonctionnalités de l'interface développée.

Le chapitre **6** termine la deuxième partie de ce manuscrit en présentant trois exemples d'analyse d'images RSO multi-temporelles par la stratégie "extraction-fusion". Les résultats obtenus par fusion floue interactive sont comparés à ceux obtenus par deux méthodes de classification, les C-Moyennes Floues et les SVM (Machine à Vecteurs de Support), présentées respectivement dans les annexes **D** et **E**. Les performances sont évaluées à l'aide de matrices de confusion dont les principes sont rappelés dans l'annexe **F**.

Première partie

Etat de l'Art et Données

Expérimentales

Chapitre 2

Analyse d'images RSO multi-temporelles

L'analyse d'images radar à synthèse d'ouverture multi-temporelles est fondée sur les deux aspects primordiaux de ce type de données : le capteur d'acquisition de type actif (cf. annexe A) et l'existence d'une troisième dimension pour les données : le temps. L'aspect actif du capteur ouvre des possibilités d'utilisation de la télédétection sur de créneaux/intervalles non-accessibles aux autres types de capteurs : la nuit et dans des zones géographiques difficilement accessibles (zones tropicales humides et zones arctiques). L'aspect multi-temporel rend possible le suivi des évolutions ou l'amélioration des détections. L'analyse d'images multi-temporelles peut être définie comme "l'examen d'images afin de détecter et d'identifier des objets par leur caractéristiques spatiales et/ou temporelles". L'analyste étudie les données de télédétection et essaye de détecter, identifier, classifier, mesurer et évaluer la signification des objets physiques, leurs modèles et leurs rapports spatio-temporels.

Dans ce chapitre nous introduisons l'analyse d'images de télédétection, avec des données optiques et RSO. Nous faisons ensuite un survol de la littérature relative aux méthodes et au domaine de la télédétection multi-temporelle, optique et RSO, avec son application spécifique : la détection de changements.

2.1 Télédétection multi-temporelle

2.1.1 Types de capteurs et de données

Les différents types de capteurs, et les données produites, peuvent être classifiés en fonction de différents critères. Comme notre but n'est pas de donner une liste exhaustive des capteurs utilisés en télédétection, nous nous sommes limité à quelques critères intéressants dans le cadre de cette thèse.

Premièrement, selon le mode de fonctionnement, nous trouvons des capteurs *passifs* ou *actifs*. Les capteurs *passifs* détectent la radiation électromagnétique réfléchie ou émise par des sources naturelles (le soleil, la surface de la terre, etc.). En revanche, les capteurs *actifs* détectent l'énergie réfléchie par les objets illuminés par une source artificielle de radiations propre au système qui inclut le capteur. Comme dispositifs actifs, on trouve principalement des dispositifs radar ou laser. La propriété active de ce type de capteurs les rend très intéressants pour des applications où les capteurs passifs sont inutilisables. Nous pouvons mentionner l'utilisation des capteurs radar pour le suivi des zones tropicales humides, zones avec une couverture nuageuse quasi-permanente, où les capteurs optiques (passifs) sont impuissants.

Dans le cadre de la thèse nous avons travaillé avec de données sous forme d'images. Cela nous amène à faire une autre classification en capteurs *non-imageurs* ou capteurs *imageurs*. Les capteurs *non-imageurs* mesurent la radiation émise ou réfléchie de tous les points de la scène détectée, ils intègrent les mesures et ils donnent comme résultat un certain signal électrique. Au contraire, les capteurs *imageurs* captent la radiation avec une résolution suffisante pour séparer la réponse (ou l'émission) d'un ensemble de points formant un maillage bidimensionnel. Le résultat de la détection est le plus souvent une image ou une matrice de données.

Les images de télédétection sont disponibles sous deux formes : des images photographiques et des images numériques. Dans le cadre de cette thèse nous nous sommes intéressés seulement aux images numériques, donc lorsque nous parlons d'images de télédétection nous comprenons seulement cette catégorie.

Afin qu'un capteur récolte et enregistre l'énergie reflétée ou émise par une cible ou une surface, il doit résider sur une plate-forme stable et qui ne se trouve pas en contact avec la cible ou la surface à détecter. Les plates-formes utilisées pour porter les capteurs peuvent être situées sur la surface terrestre (plates-formes au sol), dans l'atmosphère (plates-formes

aéroportées), ou dans l'espace extra-atmosphérique (plates-formes satellitaires ou navettes spatiales).

Pour conclure, les applications de télédétection utilisent des images acquises avec des capteurs passifs (optiques) ou actifs (radar), imageurs et aéroportés ou satellitaires. Dans les sections suivantes nous allons présenter les données utilisées et rappeler les caractéristiques des plates-formes qui les ont fournies. Une dernière section est dédiée aux informations complémentaires, comme les cartes, les données des systèmes d'information géographique (SIG) et les modèles numériques de terrain utilisés en complément des données optique/radar pour la détection de changements.

2.1.2 Données optiques

Les données optiques sont acquises avec des capteurs imageurs qui mesurent la radiation visible ou la radiation infrarouge (proche infrarouge, infrarouge intermédiaire, ou infrarouge thermique). Il y a deux genres de méthodes d'observation à l'aide des capteurs optiques utilisés en télédétection : la télédétection visible/proche infrarouge et la télédétection infrarouge thermique.

Télédétection visible/proche infrarouge

La télédétection visible/proche infrarouge est utilisée pour mesurer l'énergie rétrodiffusée par des objets situés sur la surface terrestre. En examinant l'intensité de la radiation captée, on peut analyser les états de la surface de la terre, par exemple, la répartition des plantes, forêts ou cultures, les fleuves et les lacs, les secteurs urbains, etc. Les inconvénients sont ceux des capteurs passifs : pendant la nuit et dans les zones nuageuses ces données ne sont pas utilisables.

Télédétection infrarouge thermique

La télédétection infrarouge thermique est utilisée pour mesurer la quantité d'énergie émise par la surface terrestre. Elle permet d'observer les secteurs à hautes températures, tels que les zones d'activité volcanique ou les zones incendiées. En examinant l'intensité de la radiation infrarouge thermique, on peut aussi analyser les évolutions thermiques de la surface de la terre et de la mer. Cette méthode peut être utilisée pendant la nuit s'il n'y a pas de nuages.

Plates-formes pour la télédétection optique

Les principales plates-formes utilisées pour la télédétection optique sont les plates-formes satellitaires Landsat et SPOT. Le programme Landsat, qui a commencé en 1972 avec le lancement du satellite Landsat-1, continue aujourd'hui avec le satellite Landsat-7, qui fournit des images quotidiennes des parties de la surface terrestre. Les principaux capteurs utilisés sur les plates-formes Landsat sont le capteur MSS (Multi-Spectral Scanner) et le capteur TM (Thematic Mapper). Le programme SPOT est opérationnel depuis l'année 1986. Les plates-formes SPOT incluent des outils imageurs de haute résolution avec une précision géométrique et radiométrique de haute qualité.

L'utilisation de ces données multi-spectrales qui offrent entre 3 et 7 bandes selon les capteurs depuis plusieurs décennies s'est généralisée, notamment pour des applications multi-temporelles telles que le suivi de la végétation, de l'occupation de sols, etc.

2.1.3 Données radar

Les données radar utilisées dans des applications de télédétection sont obtenues avec des radar à synthèse d'ouverture. Le *radar à synthèse d'ouverture* (RSO) est un capteur actif, imageur, monté sur des plates-formes aéroportées ou satellitaires (cf. annexe A). Les principales difficultés proviennent des effets géométriques importants. La topographie de la scène a une grande influence. La réflectivité radar est liée à la pente locale, les ombres portées masquant certaines zones de la scène. Le phénomène nommé *layover* crée des confusions entre des points d'altitudes différentes. Les multiples propriétés physiques de la scène illuminée ont des influences souvent équivalentes et créent donc des difficultés lors de l'interprétation des données, particulièrement lorsque peu d'images différentes sont disponibles. Les principaux avantages des systèmes RSO sont : la nature active du capteur, l'insensibilité aux écrans nuageux, la possibilité d'être employés pour l'observation régulière des phénomènes dynamiques tels que les courants d'océan, la dérive des icebergs et des changements dans les aires couvertes d'eau et de végétation. De plus, un système RSO permet d'observer les structures au travers de propriétés physiques différentes de celles perçues par les instruments optiques en raison de la différence de longueurs d'onde, donnant deux ensembles de données (radar et optique) complémentaires. Parmi les inconvénients, on peut citer qu'aux résolutions typiques des ensembles de données RSO satellitaires actuellement disponibles, la résolution spatiale reste faible. Les objets comme les arbres, les véhicules et les bâtiments occupent typiquement un ou deux pixels seulement. De même, le système RSO est quasi-

Bande	Fréquence (GHz)	Longueur d'ondes (cm)
P	0,225 - 0,39	133 - 76,9
L	0,39 - 1,55	76,9 - 19,3
S	1,55 - 4,20	19,3 - 7,1
C	4,20 - 5,75	7,1 - 5,2
X	5,75 - 10,90	5,2 - 2,7
K_u	10,90 - 22,0	2,7 - 1,36
K_a	22,0 - 36	1,36 - 0,83

TAB. 2.1 – Bandes de fréquence disponibles pour les systèmes RSO

ment mono-chromatique. Enfin, comme pour tout système d'imagerie cohérente, les images RSO souffrent du phénomène du chatolement (*speckle* en anglais, mot couramment utilisé en français).

Le speckle gêne fortement l'interprétation d'une image RSO. Des zones homogènes adjacentes, dont la radiométrie diffère peu, sont difficilement discernables. Les fines structures peu contrastées sont souvent noyées dans le chatolement. De plus, la nature multiplicative de ce *bruit* ne permet pas de traiter une image radar avec des outils déjà éprouvés pour des images optiques. Le speckle impose donc des approches spécifiques et des traitements adaptés à sa nature, prenant en compte toute l'information complémentaire disponible.

Bien que différentes bandes de fréquence soient possibles (cf. tab. 2.1, [MAÎTRE, 2001]) la majorité des capteurs opèrent dans une seule bande et rares sont les systèmes qui observent simultanément la réponse du sol dans différentes bandes. En revanche la polarisation de l'onde électromagnétique à l'émission et à la réception permet d'obtenir jusqu'à quatre polarisations différentes, généralement dénotés HH, HV, VH et VV, H pour des polarisations horizontales et V pour des polarisations verticales. Les systèmes aéroportés acquièrent généralement les différentes polarisations alors que jusqu'ici, les systèmes satellitaires se sont limités à une seule polarisation "simultanée" pour des raisons de résolution et de limitation du débit des données de transmission.

Plates-formes pour la télédétection radar

Les principales plates-formes qui fournissent des données RSO sont : les plates-formes aériennes AirSAR du JPL¹ et E-SAR du DLR², les missions des navettes spatiales

¹Jet Propulsion Laboratory, Etats-Unis.

²Agence Spatiale Allemande

	JERS-1	ERS-1/2	Envisat	Radarsat
Bande	L	C	C	C
Polarisation	HH	VV	VV/HH HH/HV VV/VH	HH
Altitude	568 km	782 km	800 km	797,9 km
Angle (incidence)	35°	23°	15 à 45°	20 à 49°
Résolution	18 m	20 m	selon les modes	9 à 100 m

TAB. 2.2 – Les caractéristiques des systèmes RSO satellitaires

Programme	Navette	Lancement	Altitude	Bande	Polarisation
SIR-A	Columbia	novembre 1982	259 km	L	HH
SIR-B	Challenger	octobre 1984	360, 257, 224 km	L	HH
SIR-C/X-SAR	Endeavour	avril & octobre 1994	225 km	L C X	HH HV VH VV HH HV VH VV VV

TAB. 2.3 – Les programmes SIR

américaines SIR³-A,-B,-C/X-SAR et SRTM⁴, et les satellites japonais JERS-1, européens ERS et Envisat ASAR ainsi que les satellites canadiens Radarsat (cf. tab. 2.2).

Les missions SIR et SRTM ont utilisé des vols de navettes spatiales dédiés à des acquisitions de données RSO. Les trois missions SIR ont eu lieu entre 1982 et 1994 (cf. tab. 2.3). La mission la plus récente a été la mission SRTM⁵ (11-22 février 2000). L'objectif de ce projet a été de produire, par l'interférométrie radar, des données topographiques numériques pour 80% de la surface terrestre (toutes les terres entre les latitudes 60°N et 56°S, qui contiennent 95% de la population mondiale) avec une résolution d'environ 30 mètres. La précision verticale absolue des données d'élévation est de 16 mètres.

Le système RSO aéroporté de la NASA/JPL (AIRSAR⁶) fonctionne en mode entièrement polarimétrique simultanément dans les bandes P, L et C ou en mode interférométrique simultanément dans les bandes L et C. Le système est devenu opérationnel en 1987 à bord d'un avion DC-8. Depuis, l'AIRSAR a été mis en œuvre chaque année et a acquis des images d'Amérique du Nord et du Sud, d'Amérique Centrale, et également en Europe et en Australie.

³Spaceborne Imaging Radar

⁴Shuttle Radar Topography Mission

⁵Source <http://srtm.usgs.gov>

⁶Source <http://airsar.jpl.nasa.gov/>

Le satellite JERS-1⁷ (Japanese Earth Resources Satellite) est un satellite d'observation de la terre dont le premier objectif est de recueillir des données sur les activités agricoles, forestières et piscicoles. Il a aussi été utilisé pour des activités de protection de l'environnement, de prévention des désastres et pour la surveillance côtière. Un accent a été mis aussi sur la localisation des ressources naturelles. JERS-1 a été équipé avec un capteur RSO en bande L, avec une polarisation HH, et un capteur optique qui mesure la radiation en lumière visible et infrarouge. Lancé en février 1992 et bien que conçu pour une durée de 2 ans, le satellite JERS-1 a fourni des données pendant plus de 6 années, sa mission finissant le 12 octobre 1998.

Le programme européen d'observation de la terre⁸ a été conçu pour fournir des informations continues à long terme, condition indispensable pour le travail des spécialistes en sciences de la terre. Le satellite ERS-1 a été lancé en juillet 1991, suivi en 1995 par son "jumeau" ERS-2. Ils ont été équipés d'un capteur RSO en bande C, avec une polarisation VV. ERS-2, à son tour, a été remplacé en 2002 par un satellite de nouvelle génération avec des performances améliorées, Envisat. La mission d'Envisat était de garantir la continuité des données fournies par les satellites ERS tout en diversifiant les produits radar (différents angles d'incidence, modes, polarisations). Cet objectif semble atteint en ce qui concerne les données d'amplitude, en revanche un léger décalage de la fréquence centrale a interrompu la continuité des acquisitions pour les applications interférométriques. Envisat recueille également l'information sur des composants atmosphériques.

Les données obtenues avec les plates-formes satellitaires ERS et leurs applications sont nombreuses. En quelques années, une grande communauté d'utilisateurs de données ERS s'est développée et des progrès significatifs ont été réalisés dans beaucoup de domaines de la télédétection, comme l'observation des océans et des calottes glaciaires, les applications d'interférométrie pour mesurer les mouvements du sol lors de tremblements de terre, des écoulements glaciaires et des glissements de terrain. Les applications de détection de changements réalisées avec des images radar ERS de la forêt d'Amazonie ont révélé l'impact de la déforestation sur l'environnement. Masquée par la couverture nuageuse une bonne partie de l'année, la Guyane française a été cartographiée avec succès pour la première fois par ERS-1 [UMLV-98, 1998]. Depuis, les scientifiques utilisent ces images pour étudier l'éco-système local, en particulier les marais et les mangroves.

⁷Source <http://www.eorc.nasda.go.jp/JERS-1/>

⁸Source <http://earth.esa.int/ers/>

Radarsat⁹ est une série de satellites de télédétection canadiens, initiée avec Radarsat-1, lancé en 1995 qui sera suivi de Radarsat-2, dont le lancement est prévu pour 2004. Il fonctionne dans la bande C, avec une polarisation HH et un angle d'incidence variable entre 20° et 60°. Les utilisations de Radarsat-1 incluent des applications de surveillance (icebergs, glaciers, côtes), de cartographie (globale, forestière ou de désastres), d'évaluation de gisements ou de planification urbaine ainsi que des applications sismologiques ou volcanologiques.

Applications multi-temporelles

Parmi les différentes plates-formes énumérées ci-dessus, les plates-formes satellitaires sont les plus appropriées pour la télédétection multi-temporelle grâce à la répétitivité des orbites. Ces données radar satellitaires sont de plus en plus employées en télédétection, particulièrement dans des applications sur des régions où les données optiques sont rarement disponibles. Elles permettent à des experts (géophysiciens) de détecter les changements temporels et d'améliorer la détection des structures spatiales dans diverses applications comme la cartographie des forêts [QUEGAN *et al.*, 2000], la surveillance des inondations [WEYDAHL, 1996], l'observation de la glace sur la mer [HAVERKAMP and TSATSOUKIS, 1999], la cartographie des rizières [HOLECZ *et al.*, 2001] ou la mise à jour des cartes géographiques [TRÉBOSEN *et al.*, 2000].

Avant d'analyser les images multi-temporelles, des étapes de pré-traitement sont souvent nécessaires pour établir un lien plus direct entre les données et les phénomènes physiques. Ces étapes de pré-traitement comprennent généralement une série d'opérations comme le calibrage de données, le mosaïquage et le recalage des images. Elles peuvent également inclure la réduction de speckle (filtrage) avec des filtres mono-temporels [LEE *et al.*, 1994] ou multi-temporels [TROUVÉ *et al.*, 2003], le géocodage, notamment pour la combinaison d'orbites croisées afin de réduire la perte d'information due au phénomène d'ombre et de repliement en présence du relief (voir l'annexe A). Ces dernières étapes peuvent introduire des artefacts puisque le filtrage ou le rééchantillonnage modifient les propriétés statistiques de la radiométrie et peuvent diminuer la résolution spatiale ou temporelle. Les images d'orbites répétées sont très appropriées pour la détection de changements puisque les cibles sont vues sous le même angle d'incidence et les images peuvent être recalées par translation sans rééchantillonnage, tandis que la fusion/combinaison des détections de structures effectuée

⁹<http://www.ccrs.nrcan.gc.ca/>

après rééchantillonnage donne souvent de mauvais résultats [STANCU *et al.*, 2002].

Les caractéristiques des données RSO multi-temporelles dépendent ensuite fortement du niveau de corrélation entre les différentes dates [OLIVER and QUEGAN, 1998]. Les images multi-temporelles de la plus part des terrains sont corrélées sur une période de temps courte. Elles sont faiblement corrélées si les images sont acquises à des dates espacées ou sur des orbites différentes avec des angles d'incidence différents. Lorsque les données multi-temporelles sont non-corrélées entre dates, la matrice de covariance est diagonale et toute l'information est portée dans les coefficients de rétrodiffusion et les paramètres de texture. Ces paramètres sont des caractéristiques très utilisées dans l'analyse d'images RSO [LOMBARDO and OLIVER, 1994]. Ils sont par exemple employés avec des images mono-temporelles ou des images multi-bandes/multi-polarisations pour classifier les zones agricoles [VACCARO *et al.*, 2000] ou en utilisant les concepts de segmentation optimisée de texture RSO pour classifier les forêts tropicales [OLIVER, 2000]. Dans le cas des données multi-temporelles traitées dans cette thèse, les informations de texture doivent être extraites dans chaque image ou dans l'ensemble 3D de données formé par une série d'images.

Bien que les séries multi-temporelles acquises par les satellites dotés de capteurs RSO soient plus courtes que les séries optiques acquises par SPOT et Landsat, ces données sont a priori les plus favorables à une utilisation multi-temporelle grâce à la nature tout temps du capteur. Cependant, les spécificités radiométriques et géométriques ont souvent arrêté les utilisateurs potentiels de ces données. Malgré une quinzaine d'années de développements de méthodes spécifiques aux images RSO, la mise au point d'outils de traitement des séries radar multi-temporelles adaptés aux besoins applicatifs reste un enjeu majeur pour la généralisation de l'utilisation de ces données.

2.1.4 Information complémentaire

L'information complémentaire correspond aux informations disponibles pour certaines applications et provenant d'autres sources que les capteurs de télédétection.

Cartes

La principale façon d'accéder à des informations complémentaires pour une région donnée, ou de présenter les produits finaux de l'analyse de données de télédétection, est d'utiliser des cartes. Il s'agit par exemple de cartes topographiques pour l'information de

relief ou de cartes routières pour la connaissance des réseaux de communications. Nous exploiterons ce type de données principalement sous deux formes : sous la forme d'attribut numérique issu des cartes et susceptible d'être fusionné avec d'autres attributs issus des images satellitaires, ou bien pour la construction de jeux de références utilisés dans les étapes de paramétrage, d'apprentissage ou d'évaluation des méthodes proposées.

Modèle numérique de terrain

Le relief est une caractéristique de base de la surface terrestre et un des principaux facteurs de son évolution. La topographie influence la migration et l'accumulation des substances (les eaux, la neige, etc.) déplacées par gravitation le long de la surface et dans le sol, les caractéristiques climatiques et hydrologiques, et les propriétés de la couverture de végétation. La topographie est un indicateur des structures géologiques, qui peuvent influencer les dépôts de minéraux, les centres sismiques, et peuvent affecter les caractéristiques du sol et de la végétation. De ce point de vue, le modèle numérique de terrain (MNT) est employé dans beaucoup d'analyses de la surface terrestre. En présence de relief, il permet de comprendre et éventuellement de corriger les effets géométriques et radiométriques présents dans les images RSO. Ces dernières peuvent également être utilisées pour générer des MNT par différentes techniques utilisant deux images par radargrammétrie (stéréo "classique") ou interférométrie (utilisation des différences de phase) [DUPONT, 1997] ou une seule image par radarclinométrie (approche "*shape from shading*") [PAQUERAULT, 1998].

Données SIG

Les systèmes d'information géographique (SIG) sont des systèmes informatiques utilisés pour stocker et manipuler l'information géographique. On rencontre deux catégories majeures de SIG. La première est dédiée à la gestion de données géographiques (collecte et archivage dans des bases des données), la deuxième catégorie est dédiée à leur analyse. Les données obtenues avec des SIG sont utilisées couramment pour générer ou compléter les données d'apprentissage ou les données de test dans des problèmes de classification sur des images de télédétection ce qui conduit à une amélioration sensible des performances [SOLBERG, 1999].

2.2 Détection de changements

Après avoir présenté les différents types de capteurs de télédétection et les données afférentes, nous abordons ici la problématique de la détection de changements. Dans le vaste domaine de la télédétection, la détection de changements est une des applications majeures des données multi-temporelles. Ces dernières permettent d'un part une surveillance périodique de certaines zones de la surface terrestre et d'autre part l'observation des conséquences d'événements ponctuels (tremblement de terre, inondation, etc.) lorsque des données sont acquises à plusieurs dates entourant l'événement. La détection de changements consiste à identifier des différences dans l'état d'un objet ou phénomène en l'observant à différents instants. Elle implique la capacité de quantifier ces effets temporels [SINGH, 1989].

De nombreuses méthodes ont été proposées pour atteindre cet objectif avec des données optiques. Des articles de synthèse regroupant ces travaux sont aujourd'hui disponibles [SINGH, 1989], [COPPIN *et al.*, 2001]. Néanmoins, la littérature révèle que la détection de changements est un problème complexe, coûteux et difficilement reproductible [COPPIN *et al.*, 2001]. Cette complexité augmente pour la détection de changements à partir de données RSO. Très peu de méthodes ont été proposées pour exploiter ces données de façon opérationnelle. Nous présentons ici les principales approches pour la détection de changements avec des données optiques et les quelques travaux utilisant des données radar ou une combinaison de données optiques et radar (sec. 2.2.1). La dernière section (2.2.2) sera consacrée aux applications de télédétection qui exploitent des résultats de détection de changements.

2.2.1 Approches

Les principales approches pour la détection de changements peuvent être regroupées en deux grandes catégories : les méthodes d'analyse comparative de résultats de classifications indépendantes et les méthodes d'analyse simultanée de données multi-temporelles, par classification directe ou extraction de mesures révélatrices de changements. Ces méthodes sont présentées dans les sections suivantes en analysant leur applicabilité éventuelle à l'analyse des images RSO multi-temporelles.

Comparaison post-classification

La comparaison post-classification [SINGH, 1989], nommée aussi *delta classification* par Coppin [COPPIN *et al.*, 2001], est une méthode d'analyse comparative. Elle implique une première étape de classification de chaque image de façon indépendante suivi par une comparaison pixel à pixel, caractéristique à caractéristique, ou objet à objet, en fonction du type de classification utilisé, pour détecter les zones de changement. La classification peut être supervisée ou non-supervisée. Si la classification effectuée est assez précise, le résultat de cette méthode donne des informations non seulement sur l'existence d'un changement (aspect détection), mais aussi sur la nature du changement (aspect identification).

Le principal avantage de la comparaison post-classification est que, comme les classifications sont faites séparément, le problème de recalage radiométrique est moins critique. De même, par un choix approprié de la classification, la méthode peut être utilisée sur les zones d'intérêt en écartant les caractéristiques qui ne sont pas révélatrices de changements pour l'application.

Les inconvénients de cette approche proviennent de ce que :

- La précision de la comparaison post-classification est totalement dépendante de la précision des classifications initiales. Les erreurs de classification ont un effet d'accumulation dans l'image résultat.
- L'utilisation d'une classification défectueuse, peut entraîner des fausses alarmes. Par exemple, si les étiquettes de classe assignées aux pixels situés dans les zones de transition entre classes diffèrent entre les classifications (un pixel est assigné dans une classe pour une date et dans une autre classe pour une autre date) même si le pixel appartient à une même classe, la comparaison post-classification trouvera un changement de classe alors que le changement n'existe pas.

Pour réduire les erreurs qui peuvent apparaître dans l'étape de classification cette technique s'appuie souvent sur des vérités terrain et une étape d'apprentissage.

Parmi les exemples concernant les données optiques, on trouve une méthode [HAZEL, 2001] qui, dans une première étape, réalise la classification des images en objets. La détection de changements est faite par comparaison des objets trouvés dans l'image avec un modèle de la scène. Avec cette approche au niveau objet, les vrais changements sont détectés et les fausses alarmes sont éliminées dans le résultat final, alors que la classification faisait apparaître des faux changements dus aux erreurs de classification.

Les principaux problèmes des images RSO, le speckle et l'imperfection de recalage

géométrique (cf. annexe A), affectent beaucoup ce type de méthode. Dans le cas des images RSO aériennes [WOOD *et al.*, 1988], [WHITE and OLIVER, 1990], les fluctuations de la trajectoire de l'avion introduisent de fortes erreurs de recalage. Les méthodes de classification utilisées en général pour les images RSO sont principalement des méthodes de segmentation [WOOD *et al.*, 1988], [WHITE and OLIVER, 1990], [CAVES and QUEGAN, 1994] qui mettent en évidence davantage des changements structurels que des changements radiométriques. En général, les approches par comparaison post-classification des images RSO ne donnent pas de très bons résultats.

Classification multi-dates directe

Ce type de classification [SINGH, 1989], nommée aussi *analyse composite* dans [COPPIN *et al.*, 2001], repose sur une analyse simultanée de l'ensemble des données calibrées, collectées dans les mêmes conditions, à deux ou plusieurs dates. La méthode peut incorporer une logique de décision multi-échelles. Elle est aussi nommée *classification de changements spectraux/temporels* ou *analyse de schéma de changements spectraux*. Bien que cette méthode nécessite une seule classification, elle est relativement lourde. Elle demande un grand nombre de bandes spectrales en entrée, souvent redondantes, et un grand nombre de classes en sortie. Elle nécessite aussi une bonne connaissance *a priori* sur les relations entre classes et sur la zone d'analyse. Comme les caractéristiques spectrales et temporelles ont une importance égale dans l'ensemble de données, les changements temporels ou spectraux ne sont pas facilement séparés lors du processus de classification.

Ce type de méthode d'analyse de changements est utilisé dans [YAMAMOTO *et al.*, 2001] avec des images multi-temporelles et multi-spectrales. Les auteurs réalisent une *classification multi-dates* non-supervisée fondée sur une technique de segmentation tridimensionnelle (3D). L'ensemble des images multi-temporelles et multi-spectrales est considéré comme un espace 3D et un processus de séparation en arborescence binaire est appliqué. Les blocs d'images sont divisés en utilisant des tests statistiques pour avoir une uniformité spatiale des densités spectrales. Les changements temporels sont ensuite détectés comme des frontières perpendiculaires à l'axe du temps. Cette méthode a retenu notre attention pour l'utilisation des images multi-temporelles ou multi-spectrales en tant que volume. Cette idée est reprise dans les méthodes présentées dans cette thèse.

Sur des données radar, plusieurs équipes ont tenté d'appliquer des méthodes de type *classification multi-dates*. Rignot et van Zyl [RIGNOT and VAN ZYL, 1993] ont proposé une

méthode de classification multi-dates fondée sur les estimations de la décorrelation temporelle du speckle. Engeset et Weydahl [ENGESET and WEYDAHL, 1998] et Friedman *et al.* [FRIEDMAN *et al.*, 1999] ont utilisé l'analyse des coefficients de rétro-diffusion pour classer les changements dans des zones de glaciers.

Différence et rapport d'images

Pour l'utilisation de la différence, les images doivent être parfaitement recalées géométriquement. Les valeurs correspondantes de pixels sont soustraites pour produire une nouvelle image qui représente l'image de changement. Les pixels présentant un changement dans la radiométrie se retrouvent dans les queues de distribution de l'image différence, tandis que les pixels qui ne changent pas sont groupés autour d'une valeur moyenne (nulle si les images sont radiométriquement calibrées).

Le rapport d'images calcule le quotient des valeurs de chaque pixel des images, qui doivent toujours être bien recalées géométriquement. Pour le cas de non-changement, on s'attend à ce que la valeur de ratio soit proche de l'unité. Pour une détection *absolue* du changement, c'est-à-dire quand le sens d'évolution n'est pas utile, le minimum des deux ratios possibles entre les valeurs du pixel aux deux dates sera utilisé.

Rignot et van Zyl [RIGNOT and VAN ZYL, 1993] font une comparaison entre la différence et le rapport comme méthodes de détection des changements pour les données RSO. En utilisant la différence, les changements ne sont pas détectés de la même façon dans les régions de haute intensité que dans les régions de faible intensité, car la variance de la distribution de l'image différence augmente avec le niveau d'intensité. Donc l'utilisation de la méthode de différence produit plus d'erreurs dans les régions de haute intensité que dans les régions de faible intensité. En revanche, la détection de changements avec le rapport d'images RSO ne dépend pas des intensités moyennes d'images et garantit un taux de fausse alarme constant, qui permet d'obtenir de meilleurs résultats.

Cette méthode est néanmoins très sensible à la présence du speckle. Afin de réduire son influence, le rapport des moyennes locales est généralement utilisé à la place du rapport direct entre les valeurs des pixels. Par la suite nous utilisons la méthode du rapport d'intensités moyennes pour proposer des attributs d'extraction d'informations d'images RSO.

Très utilisé en détection de contours, ce rapport a également été employé sous deux formes différentes en détection de changements comme mesure de variabilité temporelle. Après avoir fortement filtré les images multi-temporelles, Quegan *et al.*

[[QUEGAN et al., 2000](#)], appliquent en chaque pixel l'approche "ratio entre dates" et moyennent ces ratios sur une année. La mesure de changement temporel qu'ils en déduisent, appelée *mva* (moyenne de variation annuelle) est exprimée en *dB* sous la forme :

$$mva = 10 \log \left[\frac{2}{N(N-1)} \sum_{n=1}^{N-1} \sum_{n'>n} R_{nn'} \right] \quad (2.1)$$

où $R_{nn'}$ désigne le ratio entre les valeurs du pixel aux dates n et n' , N le nombre d'images de la série RSO.

La deuxième forme, proposée par Lombardo et Oliver [[LOMBARDO and OLIVER, 2001](#)], introduit un test de vraisemblance généralisé (TVG) pour la détection de changements. Le test calcule le rapport entre les moyennes géométriques et arithmétiques des moyennes locales aux différentes dates $\mu_n = \sum_{i \in w} I_{i,n}$ où $I_{i,n}$ est l'intensité radar du pixel i d'un voisinage spatial w dans l'image n . En prenant le logarithme, le test appliqué aux N images de la série s'écrit :

$$\ln \Lambda = \frac{1}{N} \sum_{n=1}^N \ln \mu_n - \ln \left(\frac{1}{N} \sum_{n=1}^N \mu_n \right) \quad (2.2)$$

Ce test a été proposé par les auteurs pour estimer les fluctuations spatiales dans la texture [[LOMBARDO and OLIVER, 1994](#)]. Il fournit une mesure d'hétérogénéité qui peut être utilisée comme référence pour évaluer les performances des attributs proposés dans le chapitre 4.

Régression d'images

La régression d'images est utilisée pour trouver les changements dans les valeurs moyennes et variances en chaque pixel pour les différentes dates. Utilisée pour la télédétection optique, cette méthode réduit les effets atmosphériques et ceux dus à l'angle du soleil. Les valeurs de pixels à une date sont considérées comme une fonction linéaire des valeurs aux autres dates. Les pixels qui ont changé entre deux dates ont des valeurs différentes des valeurs attendues fournies par la fonction de régression. Pour détecter les zones de changement, on applique un seuillage sur la différence entre la valeur observée et la valeur issue de la régression.

Singh [[SINGH, 1989](#)] utilise la régression d'images pour détecter des changements dans les forêts tropicales, avec des résultats comparables aux méthodes de différence d'images, et Ridd et Liu [[RIDD and LIU, 1998](#)] pour la détection de changements en milieu urbain.

Dans le cas des données RSO, la régression d'images a été utilisée pour l'estimation de l'amplitude du coefficient de rétrodiffusion [FRANSSON *et al.*, 2002] mais sans objectif de détection de changements.

Transformations d'images

L'analyse en composantes principales (ACP) est une transformation orthogonale utilisée pour décorréler des données. Dans le nouveau système de coordonnées, les matrices de corrélation et de covariance sont diagonales. Les axes du nouveau système de coordonnées orthogonales sont définis par les vecteurs propres. Chaque canal associé à un vecteur propre peut être considéré comme une nouvelle "image" spectrale et chaque coordonnée d'un pixel comme la valeur de la "luminosité" dans cette "image".

L'analyse en composantes principales peut être envisagée aussi dans le cas multi-temporel quand les coordonnées de l'espace original ne sont pas des bandes spectrales mais des images acquises à différentes dates. Nous constatons, qu'il y a une forte corrélation dans les zones stables et une faible corrélation dans les zones de changement. En fonction du type de changement, les zones variables seront mises en évidence différemment dans les composantes principales (CP) : les zones de changement abrupt dans les CP de "haute fréquence", tandis que les zones de changement progressif de la luminosité dans les CP de "basse fréquence". La dénomination "haute fréquence" et "basse fréquence" est choisie par analogie avec d'autres transformées orthogonales telles que la transformée de Fourier et la transformée cosinus. A notre connaissance ce type de transformations n'a été utilisé sur des données RSO multi-temporelles que pour des opérations de filtrage [COLTUC *et al.*, 2000]. Ces travaux peuvent être étendus au problème de la détection de changements.

Analyse vectorielle de changement

Les données multi-spectrales de télédétection peuvent être représentées par des vecteurs avec autant de composantes que de bandes spectrales disponibles. Chaque pixel est représenté comme un vecteur dans cet espace multi-dimensionnel, ayant comme coordonnées les valeurs radiométriques dans chaque bande spectrale. Dans l'analyse vectorielle, le changement est détecté par soustraction vectorielle entre des vecteurs décrivant chaque pixel à différentes dates. La méthode peut utiliser aussi des données transformées par analyse en composantes principales. On peut également utiliser des vecteurs décrivant un seul pixel ou des vecteurs décrivant des clusters obtenus par des méthodes de segmentation. Le

résultat de la détection est obtenu par seuillage.

Analyse statistique

Bien que les méthodes de détection de changements fondées sur des analyses statistiques ne donnent pas beaucoup d'information sur la nature du changement et sur la position précise de ce changement, elles peuvent être utilisées comme une première étape dans un chaîne de détection. Avec ces méthodes, on calcule une "différence" entre les distributions des deux ensembles de données et si le résultat dépasse un certain seuil, le changement est détecté. Dans [TOWNSHEND *et al.*, 1992] l'indicateur de changement est la demi-variance (la somme des carrés de la différence des pixels) calculée dans des images NDVI. Comme la détection de changements est faite au niveau global, les effets du recalage défectueux des images est moins gênant.

Techniques hybrides

Dans cette section sont regroupées des méthodes n'entrant pas dans les catégories précédentes. Néanmoins elles sont appliquées à la détection de changements en imagerie satellitaire. On y trouve des méthodes utilisant des algorithmes de vision par ordinateur, des systèmes à base de connaissances, des algorithmes basés sur des réseaux des neurones [GOPAL and WOODCOCK, 1996], sur la théorie de sous-ensembles flous ou sur l'évolution de l'estimation de la distribution du voisinage de chaque pixel [INGLADA, 2003].

D'autres méthodes reposent sur la composition colorée, en utilisant pour chaque canal rouge/vert/bleu une image optique ou RSO [WEYDAHL, 1996], ou sur la maximisation du rapport de vraisemblance [LOMBARDO and OLIVER, 2001], ou d'autres algorithmes hybrides [RIGNOT and CHELLAPPA, 1992]. La méthode basée sur le rapport de vraisemblance proposée par Lombardo et Pellizzeri [LOMBARDO and PELLIZZERI, 2002] détecte les changements comme des transitions en échelon dans la direction du temps. Selon l'information *a priori* disponible, la méthode construit différents détecteurs optimaux au sens du maximum a posteriori.

2.2.2 Applications

Dans cette section nous présentons les principales applications de la détection de changements, en soulignant les utilisations des données RSO. La détection de changements est utile dans beaucoup de domaines comme l'analyse de l'occupation des sols,

la surveillance de la végétation [ROGAN *et al.*, 2002], le suivi de cultures agricoles, l'estimation des déforestations [LAMBIN, 1995], l'étude des changements dans la phénologie¹⁰ de la végétation [COPPIN and BAUER, 1994], ou l'étude des changements saisonniers. La détection de changements est également utile dans l'estimation des dégâts et la surveillance des désastres [ROSIN and HERVÁS, 2001], [BOSCHETTI *et al.*, 2001], [BRIVIO *et al.*, 2001], ou la surveillance des glaciers et la mesure des changements de propriétés de la neige.

Les principaux changements de l'occupation des sols sont associés au développement des villes ou aux modifications dans l'utilisation des sols (agriculture, sylviculture, etc.). Des analyses comparatives ont été réalisées pour l'évaluation des données optiques, principalement Landsat TM [FUNG, 1990], [RIDD and LIU, 1998], et pour la fusion de données optiques (Landsat MSS et TM) et données radar (JERS-1 et ERS-1) [SHAKER and HUSSIN, 1995]. Les résultats obtenus avec des données RSO dans une classification automatique sont moindres en qualité et quantité (moins de classes) que ceux obtenus avec les données optiques. Les principales classes décelées révèlent le contenu en eau (dans les zones végétales ou dans les rizières, les lacs, la mer, etc.) ou l'existence d'agglomérations urbaines. En revanche, l'interprétation visuelle, donc l'utilisation de la connaissance experte, des données RSO a donné de meilleurs résultats, mettent en évidence des classes non détectées avec les données optiques. Aussi, l'utilisation de la combinaison données optiques-données RSO pour la classification multi-spectrale permet d'obtenir des résultats avec un plus grand nombre de classes.

Quegan donne en [QUEGAN *et al.*, 1988] une méthode de détection de changements spatiaux ou temporels, appliquée à la surveillance de zones agricoles. Les données RSO sont acquises avec une plate-forme aéroportée (AgriSAR) à quatre dates couvrant la saison de croissance des cultures agricoles. La méthode demande une très bonne calibration et l'utilisation de données complémentaires : la carte du terrain, des données optiques (Landsat MSS et SPOT), des données météorologiques et topographiques, le calendrier des cultures. De plus, pour la calibration des données RSO, la zone d'étude contenait cinq "corner reflectors".

Pour l'étude de la couverture végétale, la détection de changements a servi à évaluer les zones de déboisement/reboisement et, pour les zones reboisées, à déterminer l'âge des arbres [HOFFER and LEE, 1989], [GROVER *et al.*, 1999].

L'étude des variations saisonnières dues aux périodes de gel/dégel est basée sur la com-

¹⁰Étude de l'influence des climats sur les phénomènes biologiques saisonniers végétaux (feuillaison, floraison, etc.) et animaux (migration, hibernation, etc.); *Petit Larousse illustré*, 1989.

paraison des intensités de la rétro-diffusion radar [VILLASENOR *et al.*, 1993]. De même, les variations temporelles de la rétro-diffusion sur des forêts aux feuilles caduques ont servi pour des études, avec des résultats peu satisfaisants, des changements saisonniers de la végétation ou des paramètres structurels [PROISY *et al.*, 2000].

Les zones inondables en bordure de rivière peuvent être extraites des images RSO en comparant avec des images acquises dans des conditions normales [WEYDAHL, 1996]. Toutefois, l'écart temporel entre les acquisitions ne doit pas être trop grand puisque l'analyse des inondations peut être perturbée par les changements saisonniers ou par le développement de la végétation.

Afin de détecter les changements de la surface terrestre qui sont causés par les tremblements de terre, des images interférométriques RSO, en bande L, (JERS-1) ont été utilisées [OHKURA *et al.*, 1997], [OHKURA, 1998].

La capacité *tout-temps* des données RSO les rend très attractives pour des études glaciologiques des zones arctiques. Engeset et Weydahl [ENGESET and WEYDAHL, 1998] ont utilisé les données ERS-1, avec des informations complémentaires, pour étudier les changements de structures glaciologiques et géomorphologiques. Des données interférométriques du tandem ERS-1 et ERS-2 ont également été employées dans le même but [WEYDAHL, 2001]. Les variations de coefficients de rétrodiffusion dans les zones alpines, calculés avec des données RSO multi-temporelles acquises par le satellite ERS-1, ont montré qu'elles sont dues aux changements dans le contenu en eau dans la couche de neige et aux variations de la rugosité de la surface de neige [NAGLER and ROTT, 2000]. Le même type de données radar ERS-1 a également servi pour une étude sur la fonte des neiges [KOSKINENA and HALLIKAINEN, 1997].

2.3 Conclusions

Le domaine de la télédétection radar est en plein développement. Les propriétés de capteur actif tout-temps des radars à synthèse d'ouverture donnent des possibilités d'analyse détaillée et élargie de la surface terrestre, inaccessibles avec les capteurs de type optique/infrarouge. Néanmoins, l'utilisation de ce type de données s'avère difficile et demande encore des développements méthodologiques, prenant en compte des sources complémentaires d'information. Dans notre développement méthodologique, présenté dans les chapitres suivants, cet aspect de combinaison/fusion des informations extraites de différentes sources (radar, optique, informations complémentaires) est une des idées di-

rectrices.

Chapitre 3

Données RSO multi-temporelles

Ce chapitre est dédié à la présentation des jeux de données RSO multi-temporelles utilisées pour étudier le comportement des différents attributs, présentés dans le chapitre 4, et pour mettre en œuvre l'ensemble de la chaîne de traitement sur les applications présentées au chapitre 6. Les deux premières séries d'images sont acquises sur la Guyane française, dans les régions de Saint-Laurent du Maroni et de Kourou. La troisième série d'images est acquise sur le Cameroun, dans la région de Douala.

Une illustration partielle est présentée dans ce chapitre, les images entières et les données complémentaires sont regroupées dans l'annexe B. L'ensemble de ces données nous a été fourni par le laboratoire de Géomatériaux, Institut Francilien de Géosciences, à travers de la collaboration qu'entretient le LISTIC avec l'équipe du professeur Jean-Paul Rudant. Grâce à cette collaboration, il nous a été possible de bénéficier d'une expertise précieuse sur les données et les thématiques telles que les abattis et l'évolution côtière en milieu tropical humide.

3.1 Région de Saint-Laurent du Maroni

La première série de données RSO présente des changements temporels dans des zones tropicales. Des parties de cette série d'images sont utilisées dans le chapitre 4 pour caractériser le comportement des différents attributs : le détecteur de contours (sec. 4.2.1), la différence de contours (sec. 4.2.3) et le détecteur de changements bi-temporels (DChBT ; sec. 4.3.1). Cette série est utilisée aussi dans le chapitre 6, section 6.1 pour une application de détection de changements entre deux dates. Le site et les caractéristiques des données sont détaillés dans les sections suivantes.

3.1.1 Site

Comme dans la plupart des régions tropicales, la forêt guyanaise est soumise aux déforestations massives pour le développement d'exploitations agricoles ou pour les aménagements régionaux. La zone la plus déforestée s'étend en bordure des routes départementales D9 et D10, dans la région de Saint-Laurent du Maroni (cf. carte fig. 3.1 et fig. B.1, l'annexe B). Les exploitations agricoles, de taille de 1 à 5 hectares, sont généralement utilisées à des fins vivrières. Les déforestations appelées *abattis* sont des parcelles défrichées puis brûlées afin de gagner des zones de culture sur la forêt tropicale. Cette mise en culture est faite en fin de saison sèche avant la saison des pluies de façon non-réglémentée. Des abris, construits à partir de tôle ondulée, sont souvent présents sur les abattis.



FIG. 3.1 – Carte de la région de Saint-Laurent du Maroni (extrait de la carte fig. B.1, échelle 1 : 500 000 ©IGN).

3.1.2 Données

La série des données RSO est composée de six images multi-temporelles ERS-1 et ERS-2 (illustrée sur une portion 512×512 fig. 3.2 et en intégralité 2300×2400 en annexe B, fig. B.4). Il s'agit d'images PRI (*Precision Image*), données d'amplitude codées sur 16 bits,

échantillonnées 12,5 m, avec un nombre équivalent de vus proche de 3. Elles ont été acquises entre mai 1992 et novembre 1997, en saison sèche et en saison humide (tab. 3.1).

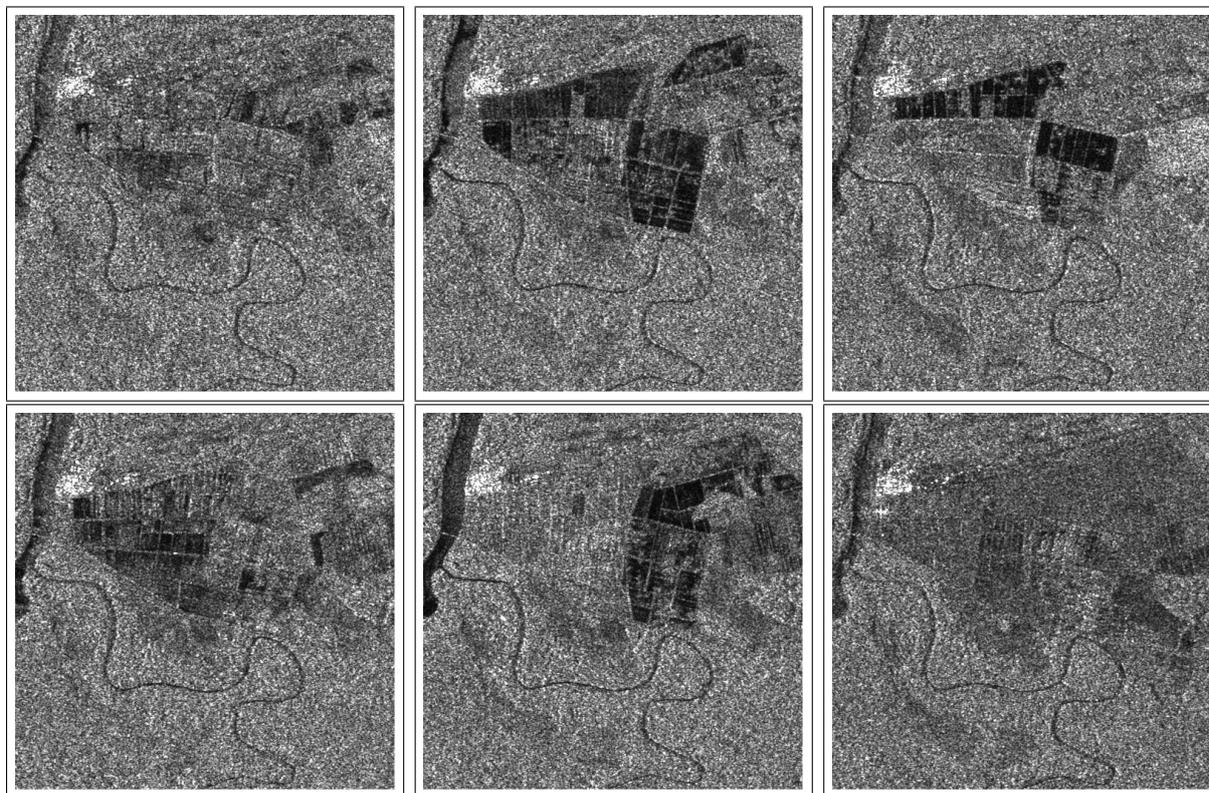


FIG. 3.2 – La zone de rizières de la série Saint-Laurent du Maroni, images 512×512 extraites des présentées fig. B.4, annexe B.

Pour la zone étudiée nous disposons des données complémentaires suivantes :

- une carte IGN à échelle 1 : 500 000, dont le réseau routier a été extrait et superposé sur une mosaïque d’images RSO rééchantillonnées (fig. B.5, annexe B, [UMLV-98, 1998]),
- des photographies aériennes acquises en 1991 et 1999, numérisées à une résolution de $600dpi$. Nous avons réalisé à partir de ces deux séries de photo-aériennes deux mosaïques qui ont été recalées sur une image radar (cf. fig. B.6). Le détail d’une des photo-aériennes est présenté dans la figure B.7, annexe B. Les zones d’abattis recherchées sont très visibles, ce que facilite la réalisation d’une vérité terrain (fig. 3.3) pour l’évaluation des performances.

Il faut noter que les images ERS sont présentées dans la géométrie radar. Par rapport à l’orientation des cartes, il y a une inversion Est-Ouest et une rotation d’environ $12,5^\circ$ degrés.

Numéro d'image	Orbite	Date	Saison
1	4220	6 Mai 1992	humide
2	4721	10 Juin 1992	humide
3	7226	12 Décembre 1992	sèche
4	9731	26 Mai 1993	humide
5	10232	30 Juin 1993	humide
6	13448	15 Novembre 1997	sèche

TAB. 3.1 – Série Saint-Laurent du Maroni, données RSO multi-temporelles acquises par les satellites ERS-1 et ERS-2, Frame 3501, orbites descendantes.

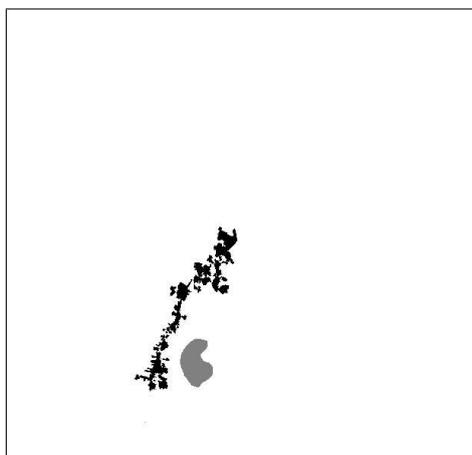


FIG. 3.3 – Masques pour l'évaluation de performances ; gris : masque de fausse alarme, M_{fa} ; noir : masque de détection, M_d , correspondant aux zones d'abattis.

3.2 Région de Kourou

Cette série de données présente une gamme complète de structures détectables. Des parties d'images de cette série ont servi pour illustrer le comportement des différents attributs dans le chapitre 4 : le détecteur de points brillants (sec. 4.1.1), le détecteur de contours multi-temporels (DCMT ; sec. 4.2.4), le détecteur de changements multi-temporels (DChMT ; sec. 4.3.2), les log-cumulants d'ordre 2 et 3 (sec. 4.4.3) et le paramètre de texture λ (sec. 4.4.3). Cette série est également utilisée dans le chapitre 6, section 6.3, pour une application de détection simultanée des structures spatiales stables et des changements temporels.

3.2.1 Site

Les images sont acquises sur la région de Kourou, Guyane française (cf. extrait de carte fig. 3.4, carte complète légende fig. B.12, annexe B).



FIG. 3.4 – Extrait de la carte de région de Kourou ©IGN.

Sur ce site, une forêt de mangroves sépare l'océan de la plaine littorale constituée de marais et de différents types de végétation. Parmi les types de végétation identifiables sur la carte (fig. B.13, annexe B), nous trouvons : des mangroves, des forêts (forêt sur cordon littoral sableux, forêt marécageuse, forêt inondable) et des savanes herbeuses (inondée, sèche, inondable) et savanes arborées. La zone retenue couvre la ville et la rivière de Kourou (à l'est), jusqu'au Centre Spatial Guyanais (à l'ouest).

3.2.2 Données

Les données radar dont nous disposons forment une série de sept images ERS-1 de type PRI, recalées par translation sans rééchantillonnage. Un extrait 600 × 700 est illustré sur 4 dates (fig. 3.5). La zone de travail entière est en fig. B.11 de l'annexe B. Les images ont été

acquises sur des passages répétés au-dessus de la région proche de la ville de Kourou, dans l'intervalle mai 1992 - novembre 1993, couvrant la saison sèche et la saison humide (tab. 3.2). Cet ensemble de données est accessible sur le site du IEEE-Geoscience and Remote Sensing Data Fusion Committee [[GEOSCIENCE and REMOTE SENSING SOCIETY](#),].

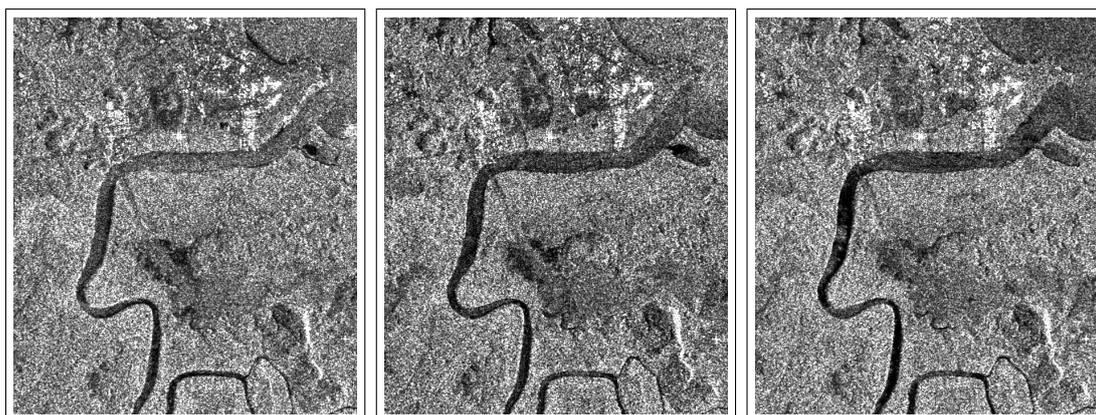


FIG. 3.5 – Extraits des trois images (1,4,7; tab. 3.2) des la série des données multi-temporelles de la zone de Kourou, Guyane française (fig. B.11 en annexe B).

Numéro d'image	Orbite	Date	Saison
1	4177	3 Mai 1992	humide
2	4678	7 Juin 1992	humide
3	7183	29 Novembre 1992	sèche
4	8686	14 Mars 1993	humide
5	10189	27 Juin 1993	humide
6	11692	10 Octobre 1993	sèche
7	12193	14 Novembre 1993	sèche

TAB. 3.2 – Série Kourou, données RSO multi-temporelles acquises par le satellite ERS-1, Frame 3501, orbites descendantes.

Une vérité terrain (fig. 3.6, extrait de la vérité terrain complète dans la fig. B.14, annexe B) réalisée avec l'aide de spécialistes du site, est aussi disponible pour constituer des masques d'apprentissage et des masques d'évaluation de performances, pour des applications en détection de structures spatiales et de changements temporels (sec. 6.3).

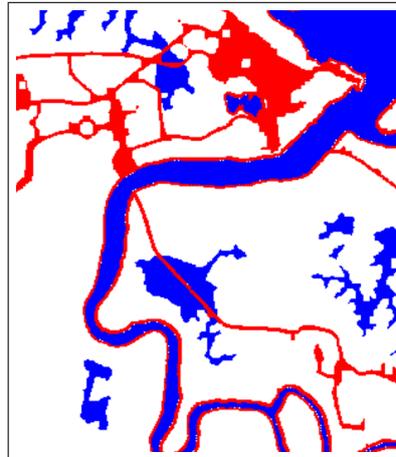


FIG. 3.6 – Vérité terrain pour la région du Kourou : bleu - zones de changements temporels ; rouge - zones avec des structures spatiales stables ; blanc - zones homogènes de point de vue spatial et temporel.

3.3 Région de Douala, Cameroun

La série de Douala, Cameroun est composée de trois images RSO (ERS-1 et ERS-2), deux acquises sur une orbite descendante et une sur une orbite ascendante. Des parties d'images de cette série ont servi pour illustrer le comportement de l'attribut détecteur de lignes (sec. 4.2.2, chap. 4) et pour étudier l'apport de la fusion d'informations pour l'amélioration des détections de structures spatiales stables (une route dans ce cas) dans un exemple d'application (chap. 6, sec. 6.2. Ce jeu de données nous permet d'illustrer un aspect complémentaire à la détection de changements dans l'utilisation des images RSO multi-temporelles : l'exploitation de la redondance d'informations pour améliorer la détection de structures noyées dans le speckle.

3.3.1 Site

La région étudiée est située sur le littoral camerounais, au niveau de la ville de Douala et des estuaires des rivières Wouri et Dimamba (cf. carte fig. 3.8 et fig. B.15, annexe B). Ce site ne présente pas d'évolutions temporelles importantes entre les dates dont nous disposons. Néanmoins, la végétation de mangroves qui se développe dans l'estuaire du Wouri, subit les influences liées à la croissance de la ville de Douala. A l'est de la ville de Douala s'étend une route qui traverse la rivière de Dimamba (fig. B.16, annexe B). Cette route sert de zone de test dans l'application de détection des structures stables développée au chapitre 6.

L'intérêt thématique est ici la mise à jour de cartes géographiques dans des zones dont la couverture nuageuse rend impossible l'utilisation d'images satellitaires optiques et pour lesquelles il n'est pas organisé de campagnes aériennes.

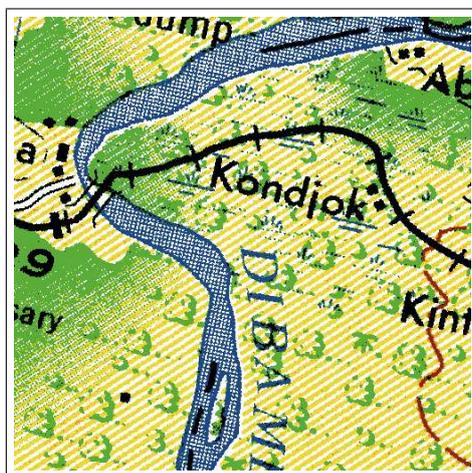


FIG. 3.7 – Extrait de la carte de la région de Douala, Cameroun.

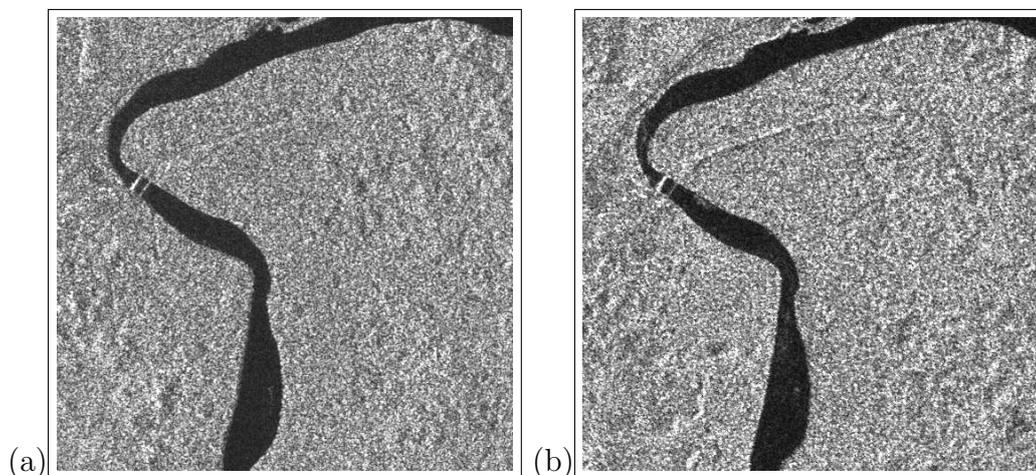


FIG. 3.8 – Extraits de la série de la région Douala : (a) orbite montante; (b) orbite descendante.

3.3.2 Données

Les images qui forment la série proviennent des satellites ERS-1 et ERS-2 et sont acquises sur différentes orbites : ascendante et descendante (tab. 3.3). Les images, illustrées figures 3.8 et B.15, sont initialement de type PRI, recalées par translation pour les 2 orbites

descendantes. La fusion avec celle de l'orbite ascendante est évaluée après rééchantillonnage de l'ensemble des images dans la géométrie de la carte IGN et codage sur 8 bits.

Numéro d'image	Satellite	Orbite	Date	Mode
1	ERS-1	16242	23 Août 1994	ascendant
2	ERS-1	22941	4 Décembre 1995	descendant
3	ERS-2	19801	2 Février 1999	descendant

TAB. 3.3 – Série Douala, données RSO multi-temporelles.

Deuxième partie

Extraction - Fusion d'Informations

Chapitre 4

Opérateurs d'extraction d'informations

L'extraction d'informations utiles pour la détection de structures spatiales ou temporelles (changements) peut être envisagée au niveau des principales primitives présentes dans les images : points, lignes, surfaces ou textures. Le calcul d'attributs relatifs à ces primitives peut se faire sur différentes combinaisons d'images multi-temporelles : une seule image, des paires d'images, ou toute la série multi-temporelle. Dans les sous-sections suivantes, nous présentons les attributs calculés pour les primitives et pour ces différentes combinaisons d'images.

Pour l'évaluation des performances des attributs présentés, en fonction du type de résultats obtenus, nous utilisons des évaluations subjectives (l'inspection visuelle des images résultats), des évaluations quantitatives globales (les histogrammes conditionnels mesurés sur des régions de référence) et des évaluations quantitatives spécifiques : les courbes des Caractéristiques Opérationnelles du Récepteur (COR¹). Le principe des courbes COR est rappelé dans la section 4.2.5. Cette approche empirique permet de comparer l'évolution de la probabilité de détection en fonction de la probabilité de fausse alarme pour différents détecteurs ou différents jeux de paramètres. Ces résultats dépendent des images analysées et des régions de référence qui doivent être sélectionnées par des personnes expérimentées en photo-interprétation d'images RSO. Lorsque les propriétés des images changent (changement de résolution, du nombre de vues, etc.) l'impact de paramètres tels que les dimensions de fenêtre d'analyse doit être réévalué. Malgré leur "spécificités", les résultats obtenus sur

¹en anglais ROC - Receiver Operating Characteristics

les données RSO multi-temporelles actuellement les plus courantes (images ERS, 3 vues) permettent de guider les utilisateurs dans le choix des attributs et leur paramétrage.

4.1 Attributs dédiés aux structures ponctuelles

Dans cette section nous présentons les attributs, dédiés aux structures ponctuelles, extraits d'une seule image ou d'une paire d'images RSO multi-temporelles. Dans le contexte de la détection de points dans les images radar, la scène est considérée comme étant composée d'un arrière-plan et d'un nombre réduit de points avec une radiométrie plus importante. Ces points représentent en général des structures artificielles et ne peuvent pas être traités comme le reste de l'image. La détection consiste à discriminer ces points brillants de l'arrière-plan voisin.

4.1.1 Données mono-date : détecteur de points brillants

Les points brillants sont des points caractérisés par une très forte rétro-diffusion et correspondent sur l'image à des cibles, qui en fonction de la résolution et de la longueur d'onde, sont typiquement des constructions métalliques, des bâtiments, des véhicules ou des navires. La méthode de détection de points brillants, considérés comme de forts réflecteurs, consiste à seuiller les amplitudes des pixels en fonction de leur probabilité d'apparition dans l'image. Dans un cadre bayésien pour détecter une cible nous avons à confronter deux hypothèses : la donnée x appartient soit à une cible C , soit à l'arrière-plan A de l'image [OLIVER and QUEGAN, 1998]. La règle de Bayes permet de relier les différentes probabilités dans chacun des cas :

$$P(C|x) = \frac{P(x|C)P(C)}{P(x)} \quad (4.1)$$

où $P(C|x)$, la densité de probabilité *a posteriori*, décrit la probabilité d'être sur un point brillant étant donnée la valeur du pixel ; $P(x|C)$, la fonction de vraisemblance, décrit la probabilité de la valeur de pixel lorsque la cible est présente ; $P(C)$ est la probabilité *a priori* pour que la cible soit présente ; et $P(x)$ la probabilité de la valeur de pixel. De même, pour l'arrière-plan on a :

$$P(A|x) = \frac{P(x|A)P(A)}{P(x)}. \quad (4.2)$$

Par application du critère du *maximum a posteriori* (MAP) une cible est détectée si :

$$\frac{P(C|x)}{P(A|x)} > 1 \quad (4.3)$$

qui s'écrit :

$$\frac{P(x|C)}{P(x|A)} > \frac{P(A)}{P(C)} \quad (4.4)$$

où le terme $P(x|C)/P(x|A)$ est le rapport de vraisemblance.

Lorsque $P(C) \approx P(A)$ l'équation 4.4 est réduite à :

$$\frac{P(x|C)}{P(x|A)} > 1$$

qui est le critère maximum de vraisemblance. Néanmoins, les probabilités a priori $P(C)$ et $P(A) = 1 - P(C)$ étant généralement inconnues pour la détection de cibles, un critère intermédiaire (observateur de Neymann-Pearson) est mieux adapté :

$$\frac{P(x|C)}{P(x|A)} > t \quad (4.5)$$

où t est un seuil défini pour une probabilité de fausse alarme donnée. Les détections réalisées avec (4.4) et (4.5) dépendent de la connaissance des fonctions de vraisemblance de la cible et de l'arrière-plan.

En pratique, seule la densité de probabilité de l'arrière-plan peut être caractérisée de façon simple. Dans ces conditions, une approche sous-optimale est adoptée :

$$P(x|A) > t. \quad (4.6)$$

En considérant un seul pixel avec la valeur positive x , la probabilité de fausse alarme et la probabilité correspondante de détection, dans une région de l'arrière plan, sont données par :

$$P_{fa} = \int_t^\infty P(x|A)dx, \quad P_d = \int_t^\infty P(x|C)dx \quad (4.7)$$

où le seuil t est choisi pour avoir un taux de fausse alarme acceptable.

Quand la fonction densité de probabilité de la cible n'est pas connue, il est impossible de obtenir une classification bayésienne optimale. Dans ce cas, le seuil est choisi empiriquement et les cibles sont détectées comme des anomalies dans la loi de l'arrière-plan.

Pour la détection de points brillants nous pouvons utiliser un seuillage global, auquel cas nous considérons que le fond est défini par toute l'image et le seuil est déterminé à partir des statistiques globales de l'image. Nous remarquerons que ce type de méthode convient bien pour des points isolés, mais est peu adapté au milieu urbain dense dans le cas de résolutions satellitaires (pixels de 25m rééchantillonnés à 12,5m).

La méthode de détection des points brillants la plus simple consiste alors à calculer la moyenne pour une image de taille $n_c \times n_l$ par :

$$\mu_{image} = \frac{1}{n_c \times n_l} \sum_{i=0}^{65535} i \cdot h[i] \quad (4.8)$$

où i désigne les niveaux de gris et $h[i]$ l'histogramme de l'image codée sur 16 bits.

L'écart type est obtenu par :

$$\sigma_{image} = \sqrt{\mu_{image^2} - \mu_{image}^2} \quad (4.9)$$

où

$$\mu_{image^2} = \frac{1}{n_c \times n_l} \sum_{i=0}^{65535} i^2 \cdot h[i] \quad (4.10)$$

Le seuil pour le détecteur de points brillants est alors calculé par la formule, souvent employée dans le contexte d'une distribution normale :

$$s = \mu_{image} + 3\sigma_{image} \quad (4.11)$$

et est utilisé pour la détection selon la relation :

$$Pb(x, y) = \min\left(\frac{s}{I(x, y)}, 1\right) \quad (4.12)$$

où $I(x, y)$ est la valeur du pixel de l'image.

4.1.2 Données multi-dates : différence de points brillants

Pour construire un attribut relatif à l'apparition ou la disparition de points brillants nous utilisons la différence entre les réponses du détecteur donné par l'équation 4.12 sur deux images :

$$dpb = \Delta Pb = Pb_2 - Pb_1 \quad (4.13)$$

Cette différence donne des valeurs négatives pour les points brillants détectés dans la première image et des valeurs positives pour ceux détectés dans la deuxième image. Le sens choisi correspond au codage établi au tableau 4.1 : noir pour les valeurs négatives ($Pb_1 > Pb_2$), blanc pour les valeurs positives ($Pb_2 > Pb_1$) et gris en l'absence de détection.

4.1.3 Utilisation et résultats

Pour faciliter l'interprétation visuelle des attributs extraits, nous utilisons deux méthodes de codage en niveau de gris en fonction de la dynamique d'évolution des valeurs des attributs. Lorsque les attributs calculés ont une dynamique asymétrique, c'est-à-dire un seul sens d'évolution des valeurs calculées entre la non-détection et la détection, le codage est fait sur toute la gamme de niveau de gris disponible, donnant des zones foncées pour la non-détection et de zones claires pour la détection. Lorsque les attributs ont une dynamique symétrique, ou quasi-symétrique, c'est-à-dire une évolution de la non-détection, qui se trouve à l'intérieur de l'intervalle des valeurs, vers la détection, qui peut prendre de valeurs dans les deux extrémités de la dynamique, la méthode de codage est présentée au tableau 4.1. Ce codage permet de tenir compte du sens de l'évolution, par exemple dans les images d'attributs calculées comme une différence ou un rapport entre deux images, les parties où la différence est causée par une radiométrie plus forte dans la deuxième image apparaissent plus claires, alors que si la radiométrie est plus forte dans la première image, les zones de changement apparaissent plus foncées. Les parties qui sont proches du gris (128) correspondent aux zones où la différence est très petite.

Valeur	Codage	Interprétation
$[-1,0[$	0-127	détection vers l'extrémité inférieure de la dynamique
0	128	non-détection
$]0,1]$	129-255	détection vers l'extrémité supérieure de la dynamique

TAB. 4.1 – Méthode de codage pour des attributs avec une dynamique symétrique ou quasi-symétrique.

La figure 4.1 présente, sur des images de la série Saint-Laurent du Maroni, Guyane française (sec. 3.1 ; 4.1-a,b), les résultats du détecteur de points brillants (fig. 4.1-c,d), et de la différence de points brillants fig. 4.1-e. La région utilisée pour illustrer le comportement de cet attribut est une région de 400×400 pixels en voisinage de la ville de Saint-Laurent

du Maroni, qui contient des informations ponctuelles intéressantes pour notre approche. L'aspect "poivre et sel" du résultat traduit les fortes fluctuations de la détection de points brillants sur la ville, tout en mettant en évidence l'apparition de quelques structures. Le résultat apparaît néanmoins comme difficilement exploitable dans un objectif de classification de chaque pixel de l'image.

Le problème de détection de structures ponctuelles (points brillants, cibles, etc.) reste un problème difficile abordé différemment en fonction des applications et de la résolution disponible. Dans le cas de données de haute résolution, la détection de cibles se transforme souvent en problème de reconnaissance avec des modèles de cibles. Dans un contexte urbain, en raison de la superposition des différents mécanismes de rétrodiffusion mal maîtrisés en ville, le problème est encore ouvert.

En raison des résultats obtenus aux résolutions satellitaires actuelles, l'utilisation de la détection de points brillants n'est possible que dans un contexte de fusion d'informations. Les attributs ponctuels peuvent être pris en compte dans l'étape de décision pour un raffinement des résultats obtenus avec d'autres attributs.

4.2 Attributs dédiés aux structures linéaires

Si la détection des structures ponctuelles se fait dans un contexte particulier, la détection des structures linéaires (contours, lignes, etc.) est plus générale. Dans cette section nous présentons les attributs relatifs aux structures linéaires pour les données mono-date et multi-dates. Dans le cas mono-date, nous rappelons le principe du détecteur de contours basé sur le rapport des radiométries moyennes. Ensuite, nous présentons un détecteur de ligne qui utilise ce détecteur de contours. Pour le cas multi-dates, nous proposons deux détecteurs : un détecteur de changement par la différence de contours et un détecteur de structures spatiales stables appelé détecteur de contours multi-temporels (DCMT).

4.2.1 Données mono-date : détecteur de contours

La plupart des détecteurs de contours classiquement utilisés en traitement d'images sont de type gradient et reposent sur une différence de moyennes locales. Ces détecteurs sont inadaptés à l'imagerie radar car leur probabilité de fausse alarme augmente avec la radiométrie des régions sur lesquelles ils sont appliqués. Des adaptations ont donc été proposées pour s'affranchir de ce défaut lié à la nature multiplicative du bruit dû au speckle,

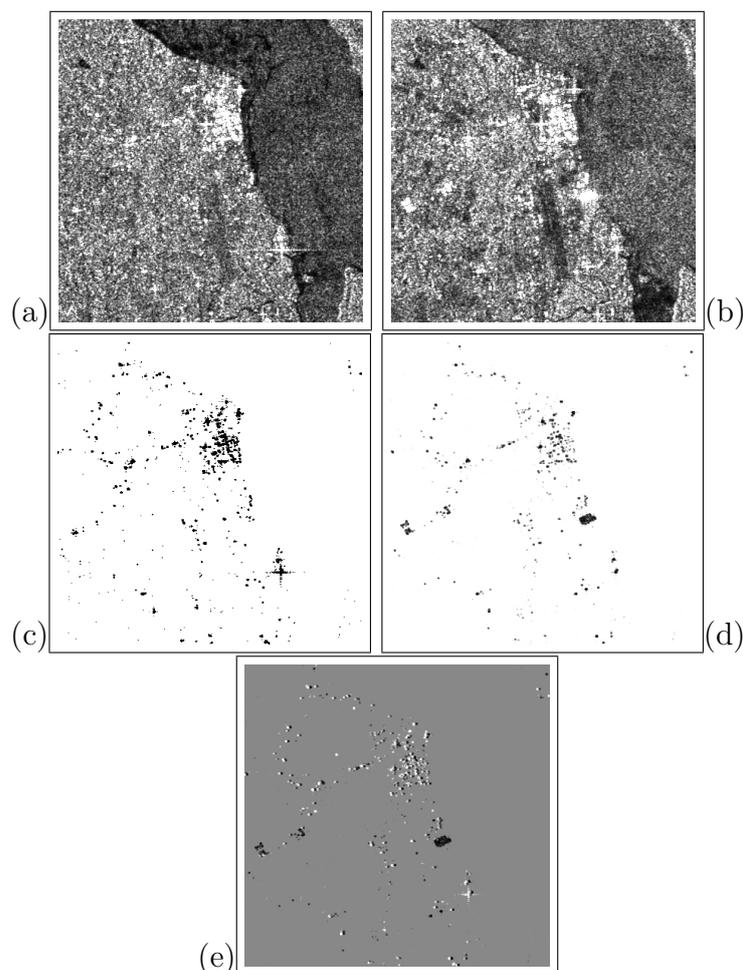


FIG. 4.1 – Images contenant des informations ponctuelles (a,b), résultats du détecteur de points brillants (c,d) et de la différence de point brillants (e).

parmi lesquelles l'utilisation du rapport des moyennes arithmétiques [TOUZI *et al.*, 1988], issu de la même démarche *maximum a posteriori* (MAP) que celle présentée dans la section 4.1. Le résultat est un détecteur à taux de fausse alarme constant (TFAC) sur toutes les zones homogènes de l'image, indépendamment de la radiométrie locale d'une région [MAÎTRE, 2001].

Considérons le cas d'un contour délimitant deux voisinages V_1 et V_2 constitués de zones homogènes de radiométries moyennes $\hat{\mu}_1$ et $\hat{\mu}_2$ comme indiqué sur la figure 4.2. On définit le contraste r par :

$$r = \frac{\hat{\mu}_1}{\hat{\mu}_2} \quad (4.14)$$

Pour avoir une valeur normalisée entre $[0,1]$, on peut utiliser [TOUZI *et al.*, 1988] :

$$r = \min \left(\frac{\hat{\mu}_1}{\hat{\mu}_2}, \frac{\hat{\mu}_2}{\hat{\mu}_1} \right) \quad (4.15)$$

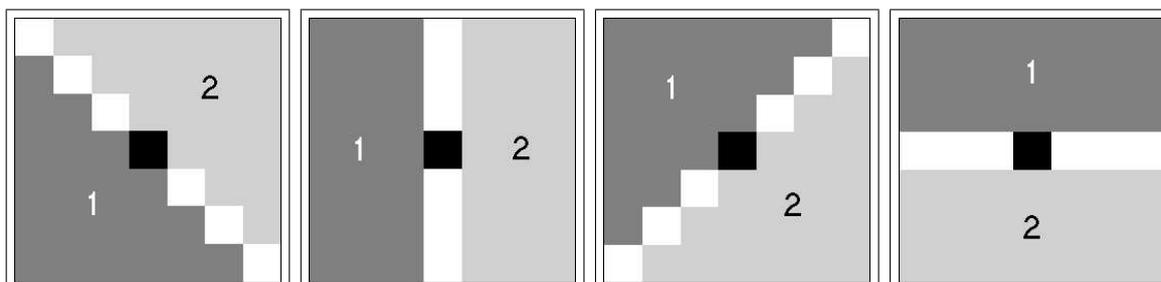


FIG. 4.2 – Exemples des voisinages utilisés pour la détection de contours.

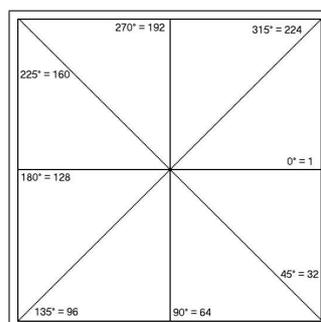


FIG. 4.3 – Codage des orientations.

Nous utilisons cette méthode avec un ensemble de masques définissant différentes directions. Les 4 masques, illustrés en figure 4.2, correspondent aux directions horizontale, verticale et aux deux diagonales. Nous ne conservons que la réponse minimale (le plus fort contraste) et l'information d'orientation associée qui correspond à la perpendiculaire au contour. Pour le codage de cette information (l'orientation du «gradient») nous avons converti l'angle $[0, 360°[$ en niveau de gris sur $[1,255]$ (fig. 4.3). La valeur «0» est conservée pour indiquer l'absence de direction (bord, les 4 rapports égaux à 1). La figure 4.4 présente un résultat du détecteur de contour appliqué sur une image de la série Saint-Laurent du Maroni, Guyane française (sec. 3.1).

4.2.2 Données mono-date : détecteur de lignes

Certaines structures spatiales telles que les routes sont trop étroites pour être correctement détectées par une approche contour. Un détecteur plus spécifique, dit «détecteur de

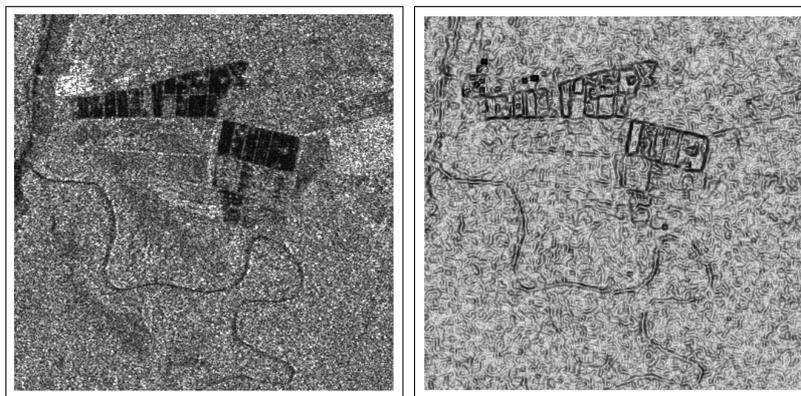


FIG. 4.4 – Détection de contours sur une image de la série de la région de Saint-Laurent du Maroni, Guyane française.

lignes”, doit alors être appliqué pour extraire ce type d’information. Le détecteur de lignes présenté dans ce paragraphe est basé sur le détecteur de contours présenté antérieurement dans la section 4.2.1. Le détecteur de lignes utilise deux détecteurs de contours fondés sur le contraste normalisé donné par l’équation (4.15), et retient le minimum d’entre eux :

$$dl = 1 - \min(r_{01}, r_{12}) \quad (4.16)$$

où r_{01} et r_{12} sont les contrastes normalisés entre les régions A_0 - A_1 et A_1 - A_2 (fig. 4.5). Pour chaque pixel de l’image d’entrée, on calcule dl_k , le détecteur de lignes (4.16), pour les k directions du masque, $k \in \{1, \dots, N_{dir}\}$, où N_{dir} est le nombre total de directions. Le résultat de la détection de ligne sera :

$$dl_{out} = \max(dl_k) \quad (4.17)$$

Le résultat présenté dans la figure 4.6 montre la détection de ligne faite sur une image représentant une partie de la région de Douala, Cameroun (ch. 3, sec. 3.3). Dans cette image on trouve des structures linéaires comme des routes et des bords de rivière. Le codage du résultat est fait classiquement en utilisant les 256 niveaux de gris pour coder l’intervalle $[0, 1]$. La détection de lignes sur une seule image montre beaucoup de fausses structures, qui rendent impossible une détection par simple comparaison à un seuil, mais demande une approche plus élaborée qui utilise la fusion de détections sur plusieurs images multi-temporelles (ch. 6, sec. 6.2).

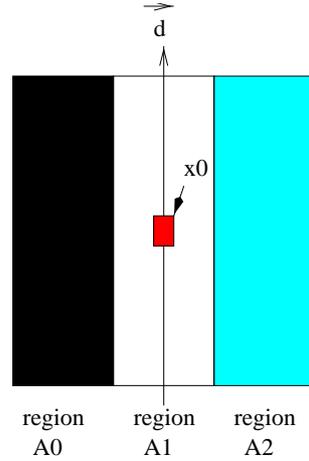


FIG. 4.5 – Forme de détecteurs de lignes.

4.2.3 Données multi-dates : différence de contours

Dans une optique de détection de changements, pour des paires d'images, le calcul de l'attribut de différence de contour se fait en considérant pour chaque pixel la réponse du détecteur sous la forme d'un nombre complexe z qui a comme module $(1 - r)$ et comme argument θ , l'orientation du contour (cf. sec 4.2.1).

L'attribut de différence de contours entre deux images est alors donné par :

$$dc = |z_1 - z_2| = |(1 - r_1)e^{i\theta_1} - (1 - r_2)e^{i\theta_2}| \quad (4.18)$$

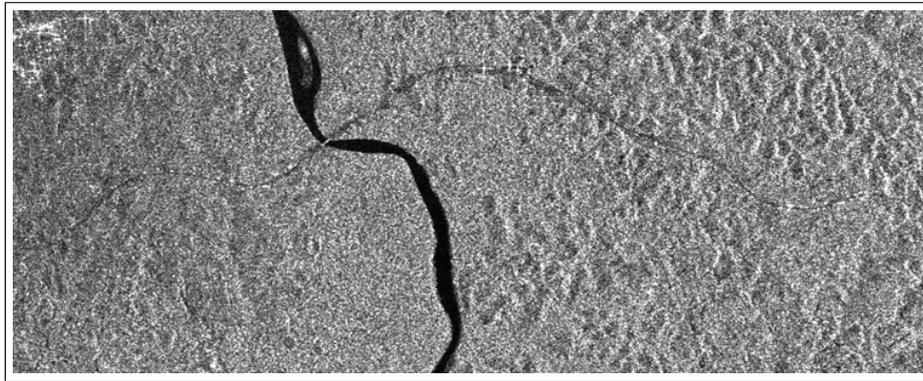
Afin de limiter l'influence de contours "faibles" sur la mesure de différence entre contours, on effectue un seuillage préalable sur le module de z : $|z| = 0$ si $|z| < 0,5$.

Le codage de cette différence s'effectue selon la convention donnée au tableau 4.1 par :

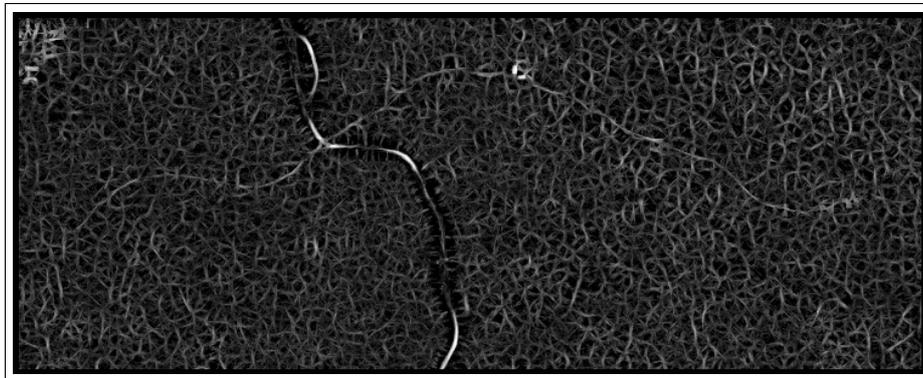
$$dc = \begin{cases} - |(1 - r_1)e^{i\theta_1} - (1 - r_2)e^{i\theta_2}|, & |z_1| > |z_2| \\ |(1 - r_1)e^{i\theta_1} - (1 - r_2)e^{i\theta_2}|, & |z_1| < |z_2| \end{cases} \quad (4.19)$$

On obtient ainsi des valeurs négatives quand le contour est plus fort dans la première image et des valeurs positives quand le contour est plus fort dans la deuxième image (fig. 4.7). Les résultats obtenus sont illustrés sur la zone de rizière de la série Saint-Laurent du Maroni. On peut observer deux types d'informations :

1. la détection des bords de parcelles qui apparaissent uniquement dans l'une ou l'autre des images. Ces détections correspondent à l'information recherchée. Cet attribut pourra être utilisé pour raffiner une détection de changements issue du détecteur de type *surface* (sec. 4.3) ou *texture* (sec. 4.4). En effet, ces derniers nécessitent des



(a)



(b)

FIG. 4.6 – Détection de structures fines : (a) image ERS de la région de Douala, Cameroun ; (b) image résultat du détecteur de lignes dl eq. (4.17).

fenêtres d'estimation relativement étendues qui dégradent la résolution spatiale des résultats.

2. une alternance de détections noir/blanc le long de structures stables telles que la rivière. Ces détections sont dues à une plus ou moins bonne visibilité des contours dans l'une ou dans l'autre des images ou une localisation légèrement différente qui peut être imputée au recalage. Dans ce cas, il est préférable de ne pas prendre en compte ces détections comme du "changement", mais de chercher à exploiter la redondance et la complémentarité des détections partielles en construisant un détecteur de contours multi-temporels, tel que celui proposé section 4.2.4.

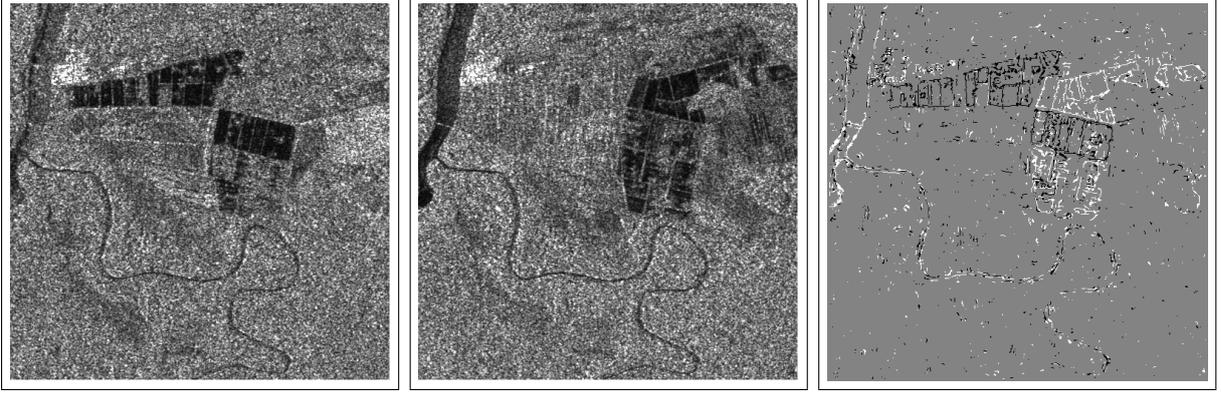


FIG. 4.7 – Différence de contours sur des images de la série Saint-Laurent du Maroni, Guyane française : noir - valeurs négatives, blanc - valeurs positives.

4.2.4 Données multi-dates : détecteur de contours multi-temporels (DCMT)

Dans une optique de détection de structures stables, nous utilisons le détecteur de contours décrit dans la section 4.2.1, en l'appliquant sur chaque image d'une série multi-temporelle. Ensuite, une fusion numérique des résultats est proposée pour retirer l'information des N images disponibles. En chaque pixel de chaque image I_n , $n \in [1, N]$, nous utilisons les deux informations fournis par le détecteur de contours : l'orientation dans laquelle le contraste est le plus grand θ_n , et la force du contour s_n dérivée du rapport normalisé :

$$s_n = 1 - r_n = 1 - \min \left(\frac{\hat{\mu}_{1n}}{\hat{\mu}_{2n}}, \frac{\hat{\mu}_{2n}}{\hat{\mu}_{1n}} \right) \quad (4.20)$$

Les forces et les directions sont combinées pour former les nombres complexes $z_n = s_n e^{i\theta_n}$ qui sont moyennés pour obtenir un seul détecteur de contours dont la force et l'orientation sont données, respectivement, par :

$$s = \left| \frac{1}{N} \sum_{n=1}^N z_n \right| \quad \text{et} \quad \theta = \arg \left(\sum_{n=1}^N z_n \right) \quad (4.21)$$

Par la prise en compte de la force et de l'orientation, ce moyennage conserve la force de contours temporellement stables, alors que les fortes valeurs isolées, correspondant aux fausses alarmes, sont atténuées. La réponse s du DCMT appliqué sur les données expérimentales de la région de Kourou (chapitre 3, section 3.2) est présentée en figure 4.8.

Les contours temporellement stables comme les bords de rivière ressortent avec un niveau plus fort comparé aux contours instables le long de la côte ou aux fausses alarmes dans les régions homogènes. L'information fournie par cet attribut pourra être exploitée pour détecter les structures spatiales stables dans les séries multi-temporelles en permettant notamment de discriminer les contours stables des changements temporels parmi les zones spatio-temporellement hétérogènes.

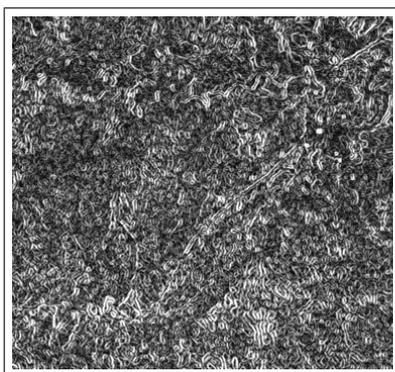


FIG. 4.8 – Résultat du détecteur de contours multi-temporels appliqué sur la série Kourou.

4.2.5 Évaluation des performances

L'évaluation de l'impact des dimensions de la fenêtre d'analyse sur les performances des méthodes de détection en fonction des propriétés des images (résolution, type de capteur, etc.) est un problème difficile pour l'analyse d'images. Ce problème est souvent traité à l'aide des courbes Caractéristiques Opérationnelles du Récepteur (COR). Ces courbes ont été tracées pour le DCMT s défini dans l'équation (4.21) pour mesurer l'influence de la taille de fenêtre et pour comparer les performances obtenues à celles d'une détection mono-date. En s'appuyant sur les régions de référence sélectionnées dans les images originales, les histogrammes de la sortie de détecteur sont calculés avec deux masques :

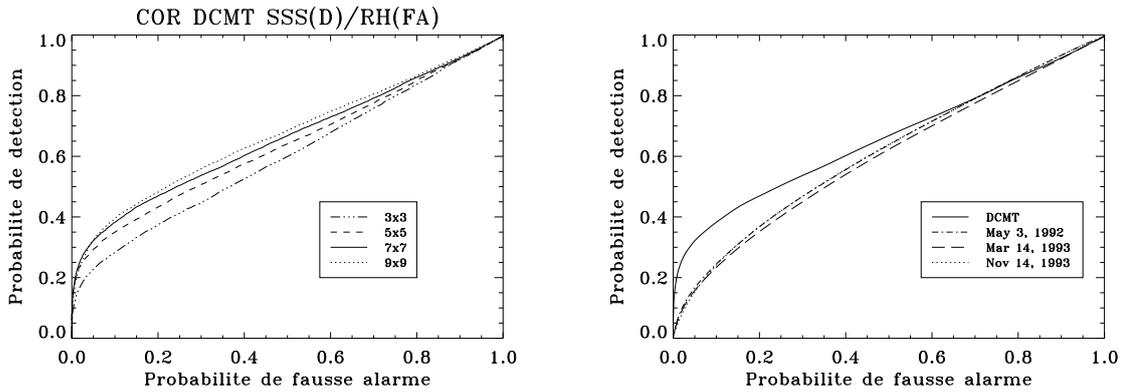
- les régions de référence contenant des structures spatiales fournissent un masque utilisé pour l'estimation de la densité de probabilité conditionnelle pour la détection $f_d(x)$,
- les régions de référence homogènes fournissent un masque pour l'estimation de la densité de probabilité conditionnelle pour la fausse alarme $f_{fa}(x)$.

Pour un seuil de décision t , la probabilité de détection $P_d(t)$ et la probabilité de fausse alarme $P_{fa}(t)$ sont :

$$P_d(t) = \int_t^1 f_d(x)dx; \quad P_{fa}(t) = \int_t^1 f_{fa}(x)dx \quad (4.22)$$

La courbe paramétrique $(P_d(t), P_{fa}(t))$ pour $t \in [0, 1]$ définit la COR pour un détecteur donné.

Les quatre courbes COR présentées dans la figure 4.9(a) correspondent aux fenêtres d'analyse de 3×3 , 5×5 , 7×7 et 9×9 . Une amélioration significative des performances est observée lorsque les dimensions de la fenêtre d'analyse augmentent jusqu'à 7×7 . Avec une dimension de fenêtre plus grande, l'amélioration de la détection est faible alors que la précision diminue, en particulier lorsque les contours ne sont pas rectilignes.



(a) Courbes COR du DCMT pour différentes dimensions de la fenêtre d'analyse.

(b) Courbes COR du DCMT et du détecteur de contours mono-date.

FIG. 4.9 – Evaluation des performances pour le détecteur de contours multi-temporels (DCMT).

En utilisant la fenêtre 7×7 , les performances obtenues avec le DCMT sont comparées avec les performances du détecteur de contour conventionnel mono-date appliqué aux différentes dates. Les courbes présentées dans la figure 4.9(b) montrent que pour n'importe quel niveau de fausse alarme, la probabilité de détection du DCMT est toujours plus grande. D'après ces résultats, le DCMT calculé avec des fenêtres 7×7 est sélectionné comme un opérateur qui révèle la présence des contours spatiaux stables dans l'approche de détection simultanée de changements et de structures spatiales stables proposée au chapitre 6, section 6.3.

4.3 Attributs relatifs aux surfaces

4.3.1 Données bi-temporelles : détecteur de changements bi-temporels (DChBT)

Pour détecter les changements qui se traduisent par un contraste important entre deux dates, nous proposons un attribut basé sur le rapport des radiométries moyennes. Le ratio donné par l'équation (4.15) est appliqué dans la direction temporelle, c'est-à-dire sur deux fenêtres à la même position spatiale dans deux images différentes au lieu de deux régions adjacentes dans la même image. Un moyennage spatial est réalisé dans chaque image suivi par une comparaison de moyennes locales $\hat{\mu}_n$ et $\hat{\mu}_{n'}$ dans les images n et n' :

$$\nu(n, n') = 1 - \min\left(\frac{\hat{\mu}_n}{\hat{\mu}_{n'}}, \frac{\hat{\mu}_{n'}}{\hat{\mu}_n}\right) \quad (4.23)$$

Cette mesure fournit un détecteur de changements bi-temporels (DChBT) utile pour révéler les variations du coefficient de rétrodiffusion entre deux images. Afin d'avoir une bonne représentation de cet attribut et conserver le sens de variation, le résultat est codé selon la convention donnée au tableau 4.1, de la façon suivante :

$$DChBT = \begin{cases} -\nu(n, n'), & \text{si } \mu_n > \mu_{n'} \\ \nu(n, n'), & \text{si } \mu_n < \mu_{n'} \end{cases} \quad (4.24)$$

Les résultats obtenus sont illustrés sur la zone de rizières de la série Saint-Laurent du Maroni (fig. 4.10). On peut observer la détection des surfaces cultivées dont la radiométrie varie fortement entre les deux images. Ces détections donnent des informations non seulement sur les zones de changements mais aussi sur le sens de ces changements. Cet attribut pourra être utilisé comme un indicateur de changements avec prise en compte du sens d'évolution ou pour une étape de détection macroscopique des zones d'intérêt (cf. sec. 6.1).

4.3.2 Données multi-temporelles : détecteur de changements multi-temporels (DChMT)

Afin d'étendre ce calcul pour un ensemble de N images ($N > 2$), une fusion numérique des $N(N-1)/2$ rapports possibles est nécessaire. Parmi les nombreux opérateurs de fusion disponibles [BLOCH, 1996], nous choisissons l'opérateur "max" pour construire le détecteur de changements multi-temporels (DChMT) :

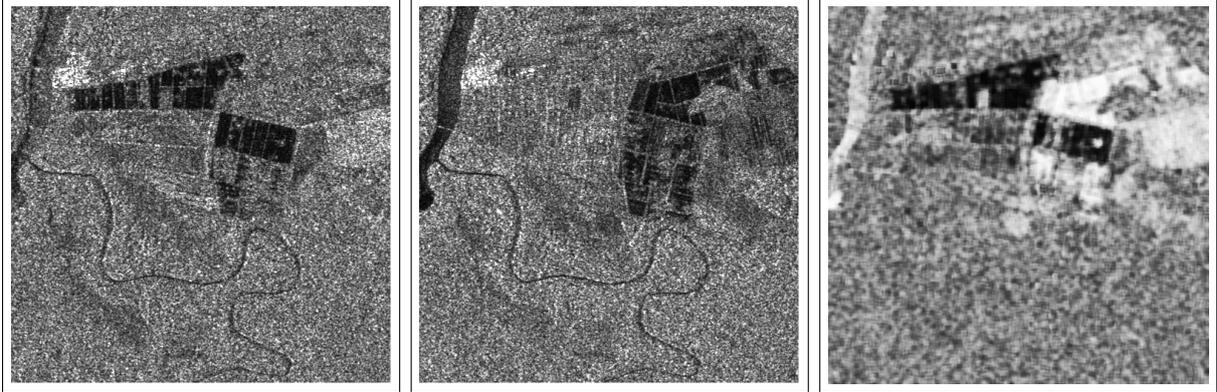


FIG. 4.10 – Résultat du détecteur de changements bi-temporels appliqué à une paire d'images de la série Saint-Laurent du Maroni, Guyane française.

$$\nu = \max_{(n,n')}(\nu(n,n')) = 1 - \min_{(n,n')} \left(\frac{\mu_n}{\mu_{n'}} \right) = 1 - \frac{\min_n(\mu_n)}{\max_{n'}(\mu_{n'})} \quad (4.25)$$

Le choix de cet opérateur consiste à sélectionner le plus grand contraste temporel entre les différentes images multi-dates. Il est motivé par le désir des géophysiciens de maintenir l'information sur le changement même lorsque le contraste est grand uniquement sur un couple d'images.

Les résultats obtenus avec le DChMT appliqué sur la série des sept images de Kourou, sont illustrés dans la figure 4.11. Plusieurs régions ayant un coefficient de rétrodiffusion temporellement variable sont révélées : régions inondées périodiquement, estuaire de la rivière à cause de l'effet du vent sur la surface de l'eau, côte pour les changements dus au mouvement de la marée et à l'érosion des mangroves.

4.3.3 Évaluation des performances

La méthode d'évaluation des performances basée sur les courbes COR, présentée au paragraphe 4.2.5, est appliquée au DChMT pour sélectionner les dimensions appropriées de la fenêtre d'analyse et pour comparer les résultats des détecteurs DChMT et DChBT. Pour ces détecteurs, les régions de référence pour le changement temporel sont utilisées comme masque de détection alors que les régions de référence homogènes sont utilisées comme masque de fausse alarme. Les courbes COR pour des fenêtres d'analyse de différentes dimensions (fig. 4.12(a)) montrent que les meilleures performances sont obtenues avec des grandes fenêtres (7×7 , 9×9). Ceci est dû au besoin d'un nombre suffisant d'échantillons pour l'es-

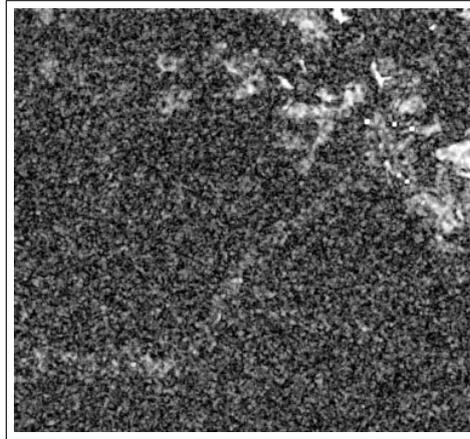
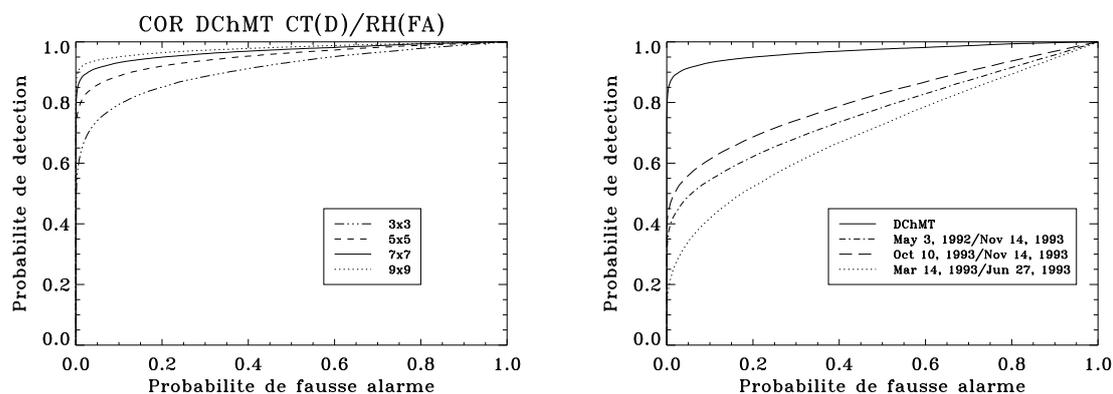


FIG. 4.11 – Résultat du détecteur de changements multi-temporels appliqué sur la série de données Kourou.

timisation des moyennes locales. La fenêtre 7×7 est toujours un compromis intéressant pour limiter l'effet de lissage (flou) des grandes fenêtres. Cette dimension de fenêtre est utilisée pour comparer les résultats du DChMT avec ceux du DChBT appliqué sur plusieurs paires d'images, y compris des paires d'images saison humide/saison sèche. Les courbes COR de la figure 4.12(b) montrent que pour n'importe quel niveau de la probabilité de fausse alarme, le DChMT augmente toujours la probabilité de détection de façon significative. Ce résultat dépend tout de même des propriétés de l'image et des régions de référence sélectionnées. En conséquence, le DChBT (7×7) sera utilisé comme attribut révélateur de l'information de changements bi-temporels entre images RSO, information qui sera combinée avec d'autres types d'informations dans l'application présentée au chapitre 6, section 6.1. Lorsque un plus grand nombre d'images est disponible ($N > 2$), le DChMT 7×7 sera utilisé comme un attribut qui révèle la présence des régions de changements temporels dans l'approche de détection simultanée de changements et de structures spatiales stables proposée au chapitre 6, section 6.3.

4.4 Attributs relatifs aux textures

Les techniques présentées dans les sections 4.2 et 4.3 fournissent des attributs fondés sur l'information de radiométrie moyenne et son contraste spatial ou temporel. Cependant, ce n'est pas le seul type d'information présent dans les séries d'images RSO. Lorsque la scène observée contient des régions clairement séparées avec un faible contenu de structures



(a) Courbes COR du DChMT pour différentes dimensions de la fenêtre d'analyse.

(b) Courbes COR du DChMT et DChBT.

FIG. 4.12 – Evaluation des performances pour le détecteur de changements multi-temporels (DChMT).

détectables, l'information utilisable pour la discrimination entre ces régions se trouve au niveau des textures. L'estimation des statistiques locales faite sur des fenêtres d'analyse de taille appropriée et l'utilisation de modèles de distribution adaptés aux images RSO permettent d'extraire ce type d'information.

4.4.1 Statistiques de deuxième espèce

Pour le développement des attributs dédiés aux textures, nous utilisons les *statistiques de deuxième espèce* développées par Nicolas [NICOLAS, 2002]. En général, les méthodes utilisées pour étudier les distributions de probabilité (d.d.p.) s'appuient sur les moments et les fonctions caractéristiques obtenues par la transformée de Fourier. Ces statistiques dites de première espèce sont bien adaptées aux distributions gaussiennes définies sur \mathbb{R} , mais les d.d.p. des données RSO détectées (amplitude et intensité) sont définies sur \mathbb{R}^+ . Il est alors préférable d'utiliser la transformée de Mellin pour définir les statistiques de deuxième espèce : fonctions caractéristiques de deuxième espèce, moments de deuxième espèce (log-moments) et cumulants de deuxième espèce (log-cumulants).

4.4.2 Fonctions caractéristiques de deuxième espèce

Dans cette section, nous rappelons la définition des fonctions caractéristiques de deuxième espèce d'où découlent les moments et les cumulants de deuxième espèce.

Soit $x \in \mathbb{R}^+$ une variable aléatoire de densité de probabilité $p_x(u)$, $u \in \mathbb{R}^+$. La *première fonction caractéristique de deuxième espèce* est la transformée de Mellin de $p_x(u)$:

$$\phi_x(s) = \mathcal{M}[p_x(u)](s) = \int_0^{+\infty} u^{s-1} p_x(u) du \quad (4.26)$$

où s est une variable complexe $s = a + jb$, avec $a \in]a_1; a_2[$ et $b \in \mathbb{R}$, a_2 pouvant tendre, dans certains cas, vers l'infini, de même que a_1 vers $-\infty$. Si $p_x(u)$ est une d.d.p., sa fonction caractéristique de deuxième espèce vérifie la propriété fondamentale :

$$\phi_x(s)|_{s=1} = 1.$$

De la même façon, on définit *les moments de deuxième espèce (log-moments)* \tilde{m}_ν , ($\nu \in \mathbb{N}$) par :

$$\tilde{m}_\nu = \left. \frac{d^\nu \phi_x(s)}{ds^\nu} \right|_{s=1}. \quad (4.27)$$

Grâce à l'une des propriétés fondamentales de la transformée de Mellin, c'est-à-dire la propriété de multiplication de la fonction originale $f(u)$ avec $(\log u)^\nu$:

$$\mathcal{M}[f(u)(\log u)^\nu](s) = \frac{d^\nu \mathcal{M}[f(u)](s)}{ds^\nu}$$

considéré en $s = 1$, les moments de deuxième espèce deviennent :

$$\tilde{m}_\nu = \int_0^{+\infty} (\log u)^\nu p_x(u) du. \quad (4.28)$$

Comme pour les moments centrés, les log-moments centrés d'ordre n , notés \tilde{M}_n , sont définis par :

$$\tilde{M}_n = \int_0^{+\infty} (\log u - \tilde{m}_1)^n p_x(u) du \quad (4.29)$$

$$= \int_0^{+\infty} \left(\log \frac{u}{\tilde{m}} \right)^n p_x(u) du \quad (4.30)$$

où $\tilde{m}_1 = \log \tilde{m}$ est la moyenne de deuxième espèce. Le second log-moment \tilde{M}_2 se retrouve de façon analogue comme étant :

$$\tilde{M}_2 = \tilde{m}_2 - \tilde{m}_1^2.$$

La *seconde fonction caractéristique de deuxième espèce* est définie comme le logarithme népérien de la première fonction caractéristique de deuxième espèce :

$$\psi_x(s) = \ln(\phi_x(s)). \quad (4.31)$$

Les *cumulants de deuxième espèce* d'ordre n , sont définis comme dérivées de la seconde fonction caractéristique de deuxième espèce (4.31), prises en $s = 1$:

$$\tilde{k}_{x(n)} = \left. \frac{d^n \psi_x(s)}{ds^n} \right|_{s=1}. \quad (4.32)$$

Comme les cumulants de deuxième espèce sont construits selon les mêmes règles que les cumulants de première espèce, les relations entre *log-moments* et *log-cumulants* sont identiques aux relations entre *moments* et *cumulants*. En conséquence, les log-cumulants des trois premiers ordres sont :

$$\tilde{k}_1 = \tilde{m}_1 \quad (4.33)$$

$$\tilde{k}_2 = \tilde{m}_2 - \tilde{m}_1^2 \quad (4.34)$$

$$\tilde{k}_3 = \tilde{m}_3 - 3\tilde{m}_1\tilde{m}_2 + 2\tilde{m}_1^3 \quad (4.35)$$

4.4.3 Calcul des attributs dédiés aux textures

Une méthode différente de mesure de la variabilité spatiale dans une seule image RSO (2D) ou la variabilité temporelle dans une série d'images RSO multi-temporelle (3D) consiste à estimer les paramètres de texture, respectivement dans des fenêtres d'analyse (2D) ou dans des petits volumes correspondants aux profils temporels des voisinages spatiaux (3D). Dans des régions homogènes du point de vue spatial (2D) ou spatio-temporel (3D), la densité de probabilité de l'intensité u , sous l'hypothèse du speckle totalement développé, est une distribution Gamma :

$$\mathcal{G}[\mu, L](u) = \frac{1}{\Gamma(L)} \frac{L}{\mu} \left(\frac{Lu}{\mu} \right)^{L-1} \exp\left(-\frac{Lu}{\mu}\right) \quad (4.36)$$

où μ est la valeur moyenne et L le nombre équivalent de vues. Dans la section précédente 4.4.2, nous avons vu que, avec la transformée de Mellin, les densités de probabilité, définies sur \mathbf{R}^+ , sont facilement modélisées par la seconde fonction caractéristique de deuxième espèce et par les cumulants de deuxième espèce (log-cumulants)[NICOLAS, 2002]. D'après ces résultats, l'estimation des statistiques de deuxième espèce, comme le second et le troisième log-cumulant, est une méthode robuste pour obtenir les paramètres des

modèles des différentes distributions : une seule distribution Gamma, un mélange additif de deux distributions Gamma, etc. Cette section est dédiée à la présentation de trois de ces paramètres utilisés comme attributs de texture pour détecter des changements temporels, dans les applications traitées au chapitre 6.

Log-cumulants d'ordre 2 et 3 comme attributs de texture

Avec la distribution Gamma, les log-cumulants d'ordre 2 et 3 sont indépendants de la moyenne μ et sont liés directement au nombre équivalent de vues L :

$$\tilde{\kappa}_2 = \tilde{m}_2 - \tilde{m}_1^2 = \Psi'(L) \quad (4.37)$$

$$\tilde{\kappa}_3 = 2\tilde{m}_1^3 - 3\tilde{m}_1\tilde{m}_2 + \tilde{m}_3 = \Psi''(L) \quad (4.38)$$

où \tilde{m}_k est le $k^{\text{ième}}$ log-moment et Ψ' , Ψ'' sont la première et deuxième dérivée de la fonction Digamma, aussi nommée fonction Polygamma. Ces relations conduisent à deux paramètres de texture, les estimés des log-cumulants d'ordre 2 et 3 :

$$\hat{\kappa}_2 = \sum_{\mathcal{V}} (\log I)^2 - \left(\sum_{\mathcal{V}} \log I \right)^2 \quad (4.39)$$

$$\hat{\kappa}_3 = 2 \left(\sum_{\mathcal{V}} \log I \right)^3 - 3 \sum_{\mathcal{V}} (\log I) \sum_{\mathcal{V}} (\log I)^2 + \sum_{\mathcal{V}} (\log I)^3 \quad (4.40)$$

où I est l'intensité du pixel/voxel (2D/3D) et $\sum_{\mathcal{V}}$ le moyennage dans la fenêtre/le volume d'estimation. On peut observer que l'estimateur $\hat{\kappa}_2$ correspond aussi à la variance de la log-intensité également retenue par Bruzzone *et al.* comme mesure de la variabilité temporelle [BRUZZONE *et al.*, 2003].

Pour le cas spatio-temporel (3D), les résultats obtenus avec ces deux paramètres estimés dans des volumes constitués de voisinages spatiaux 5×5 dans les sept images multi-temporelles de la série Kourou (ch. 3, sec. 3.2), sont illustrés dans la figure 4.13. Dans des volumes homogènes, $\hat{\kappa}_2$ et $\hat{\kappa}_3$ sont proches de leurs valeurs théoriques $\Psi'(L)$ et $\Psi''(L)$, respectivement. En présence d'hétérogénéités spatiales ou temporelles, les valeurs du log-cumulant d'ordre 2 augmentent toujours. Les caractéristiques correspondantes apparaissent en clair dans la figure 4.13(a). Pour le log-cumulant du troisième ordre, les volumes hétérogènes produisent soit des valeurs plus grandes soit des valeurs plus petites que $\Psi''(L)$, en fonction de la présence dans le volume d'analyse de valeurs d'intensité grandes ou pe-

tites. Ces valeurs apparaissent soit en clair soit en foncé dans la figure 4.13(b) où le gris correspond aux volumes homogènes.

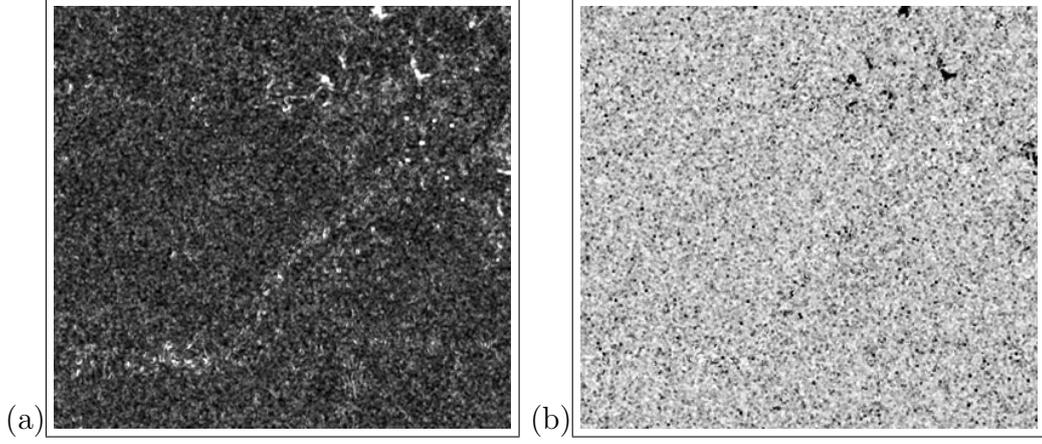


FIG. 4.13 – Résultats des paramètres de texture estimés pour la série de Kourou : (a) log-cumulant du deuxième ordre $\hat{\kappa}_2$, (b) log-cumulant du troisième ordre $\hat{\kappa}_3$.

Mélange de deux lois Gamma

Pour le cas tridimensionnel (données multi-dates analysées globalement), la présence de changements temporels dans les fenêtres d'analyse crée des mélanges de distributions Gamma. Contrairement au cas gaussien, les densités de probabilité de ces mélanges sont, en général, mono-modales, sauf lorsque les distributions initiales ont des moyennes très différentes. Un modèle simple pour analyser ces densités de probabilité consiste à faire l'hypothèse d'un mélange additif binaire de distributions Gamma :

$$\lambda \mathcal{G}[\mu, L] + (1 - \lambda) \mathcal{G}[\rho\mu, L] \quad (4.41)$$

où les paramètres $\lambda \in [0, 1]$ et $\rho \in [0, +\infty[$ décrivent respectivement le niveau de mélange (les proportions des deux distributions) et le rapport des moyennes des deux distributions Gamma.

Avec ce modèle, les expressions des log-cumulants d'ordre 2 et 3 deviennent [NICOLAS and TUPIN, 2002] :

$$\tilde{\kappa}_2 = \Psi'(L) + \log(\rho)^2 \lambda(1 - \lambda) \quad (4.42)$$

$$\tilde{\kappa}_3 = \Psi''(L) + \log(\rho)^3 \lambda(1 - \lambda)(2\lambda - 1) \quad (4.43)$$

Les variations des log-cumulants $\tilde{\kappa}_2$ et $\tilde{\kappa}_3$ sont illustrées dans la figure 4.14 pour différentes valeurs du rapport ρ et du niveau de mélange λ . La forme observée est indépendante du nombre de vues L . Les valeurs $\tilde{\kappa}_2$ augmentent toujours de la valeur minimum $\Psi'(L)$ (0.4 pour $L = 3$), jusqu'à la valeur maximum obtenue pour $\lambda = 0.5$. Ces maxima sont plus grands pour des valeurs plus grandes du rapport ρ . Les valeurs $\tilde{\kappa}_3$ sont symétriques par rapport à la valeur nominale $\Psi''(L)$ (-0.15 pour $L = 3$). $\tilde{\kappa}_3$ est plus grand que $\Psi''(L)$ dans le cas des distributions dites à *queue lourde* correspondant au renforcement de la densité de probabilité pour les grandes valeurs d'intensité, alors que $\tilde{\kappa}_3$ est plus petit que $\Psi''(L)$ lorsque le mélange introduit des valeurs de faible intensité en créant une distribution que l'on pourrait qualifier de *tête lourde*. Ce comportement peut être observé dans la figure 4.13-b (paramètre $\widehat{\kappa}_3$). Les bâtiments de la ville de Kourou et les mangroves en phase d'extinction le long de la côte créent des rétrodiffuseurs forts, donc des distributions de type *queue lourde*, qui produisent des grandes valeurs de $\widehat{\kappa}_3$, alors que pour l'estuaire de la rivière de Kourou et les zones inondables, la présence de pixels de très faibles valeurs dues aux réflexions spéculaires produit des petites valeurs de $\widehat{\kappa}_3$.

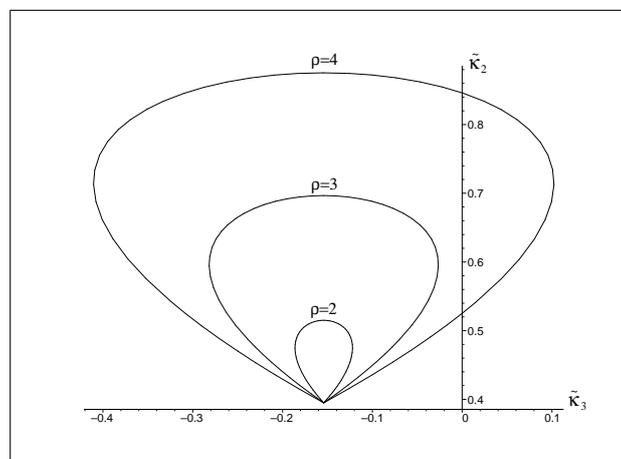


FIG. 4.14 – Valeurs théoriques $(\tilde{\kappa}_3, \tilde{\kappa}_2)$ pour un mélange binaire de distributions Gamma donné Eq. (4.41), $L = 3$, λ variant dans l'intervalle $[0, 1]$.

Dans les équations (4.42) et (4.43), le nombre équivalent de vues L est généralement connu. Dans ce cas, le système formé par ces deux équations permet à calculer les pa-

paramètres de mélange λ et ρ à partir des log-cumulants $\tilde{\kappa}_2$ et $\tilde{\kappa}_3$:

$$\lambda = \frac{1}{2} \left(1 \pm \frac{\tilde{\kappa}_{c3}}{\sqrt{4\tilde{\kappa}_{c2}^3 + \tilde{\kappa}_{c3}^2}} \right) \quad (4.44)$$

$$\rho = \exp \left(\frac{\sqrt{4\tilde{\kappa}_{c2}^3 + \tilde{\kappa}_{c3}^2}}{\tilde{\kappa}_{c2}} \right) \quad (4.45)$$

avec $\tilde{\kappa}_{c2} = \tilde{\kappa}_2 - \Psi'(L)$ et $\tilde{\kappa}_{c3} = \tilde{\kappa}_3 - \Psi''(L)$. D'après ces résultats, λ et ρ peuvent être estimés directement à partir des estimations de log-cumulants $\hat{\kappa}_2$ et $\hat{\kappa}_3$ donnés dans les équations (4.39) et (4.40).

Le résultat du calcul du niveau de mélange λ est illustré dans la figure 4.15. La solution de l'équation (4.44) qui fournit une valeur de λ dans l'intervalle $[0, 0.5]$ est utilisée pour obtenir une interprétation directe de ce paramètre, avec les structures hétérogènes apparaissant en clair.



FIG. 4.15 – Résultat du paramètre de texture λ (niveau de mélange de deux distributions Gamma) estimé pour la série de Kourou.

Dans les applications du chapitre 6, seul le niveau de mélange λ est utilisé comme paramètre de texture parce qu'il révèle la présence d'un mélange indépendamment du rapport des moyennes ρ , tandis que les caractéristiques de texture mesurées par ce rapport ρ sont proches de l'information de contraste, déjà prise en compte par les attributs de type ratio (le DChBT et le DChMT qui en découle) proposés au paragraphe 4.3.2.

4.4.4 Evaluation des performances

Pour l'évaluation des performances des attributs de texture proposés, $\widehat{\kappa}_2$, $\widehat{\kappa}_3$ et λ , leurs sorties sont mesurées dans un ensemble de trois régions de référence : structures spatiales stables, changements temporels et régions homogènes. Les histogrammes obtenus sont normalisés pour estimer les densités de probabilité conditionnelle (d.d.p.c.) présentées dans la figure 4.16. Pour le log-cumulant d'ordre 2, les modes des d.d.p.c. des régions de changements temporels et de structures spatiales stables sont déplacés vers les grandes valeurs par rapport au mode des régions homogènes qui est centré sur la valeur théorique $\Psi'(3) \simeq 0.4$ d'une distribution Gamma 3-vue. Pour le log-cumulant d'ordre 3, il est plus difficile de faire la distinction entre les d.d.p.c. des régions de changements et de structures stables et celle des régions homogènes. L'hétérogénéité des données crée des valeurs plus grandes ou plus petites pour $\widehat{\kappa}_3$, résultant en une distribution plus dispersée avec un mode toujours centré sur la valeur théorique $\Psi''(3) \simeq -0.15$ des régions homogènes. Pour le niveau de mélange, la d.d.p.c. des régions homogènes approche une distribution de Dirac en 0. La présence d'hétérogénéité apparaît dans les valeurs grandes du paramètre λ mais les d.d.p.c. des changements et des structures stables sont toujours fort au voisinage de 0. Pour ces trois paramètres, les densités des structures stables sont situées entre les d.d.p.c. des régions homogènes et celle des changements, ce qui montre la sensibilité de ces attributs de texture à la fois aux structures spatiales stables et aux changements temporels. L'estimation des statistiques avec un nombre suffisant d'échantillons requiert l'emploi de voisinages spatio-temporels. Pour cette raison, les attributs de texture basés sur les log-cumulants ne peuvent pas distinguer entre les régions hétérogènes qui ne changent pas et les régions homogènes qui changent.

La méthode d'évaluation par les courbes COR est appliquée pour étudier l'influence de la taille de la fenêtre d'analyse sur les performances en termes de détection de changements temporels. Comme pour le DChMT, le masque de détection est donné par les régions de référence CT et le masque de fausse alarme par les régions RH. Les résultats pour le log-cumulant d'ordre 2 estimés avec des volumes $3 \times 3 \times 7$, $5 \times 5 \times 7$, $7 \times 7 \times 7$ et $9 \times 9 \times 7$ apparaissent dans la figure 4.4.4-a. Pour des fenêtres spatiales plus grandes que 3×3 , le log-cumulant d'ordre 2 a une faible sensibilité aux dimensions de la fenêtre. Avec les plus grandes fenêtres, les mesures sont moins affectées par la variance d'estimation, alors que la proportion d'échantillons appartenant aux différentes "distributions" (en présence de changements temporels), n'est pas affectée par la croissance de la taille spatiale (tant que

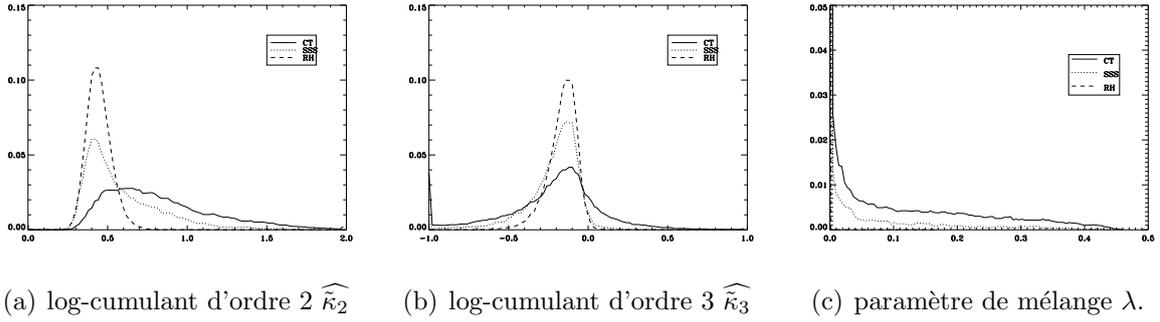
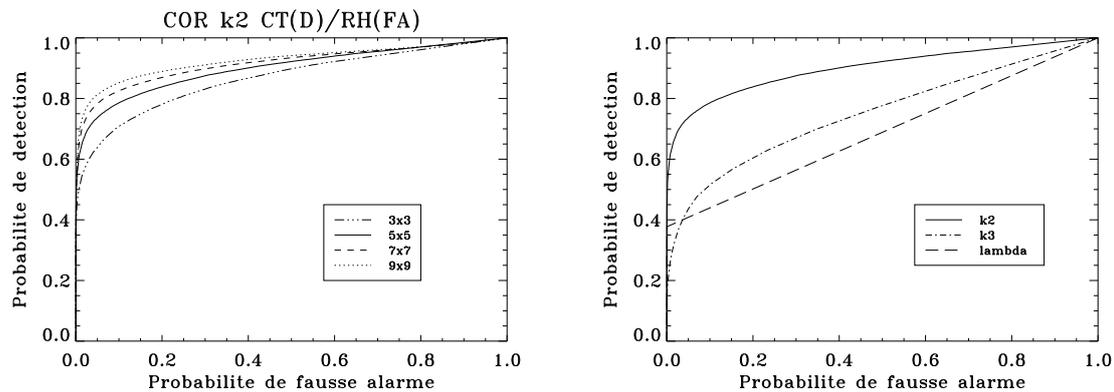


FIG. 4.16 – Densités de probabilité conditionnelle (d.d.p.c.) des paramètres de texture, calculés avec les 3 ensembles des régions de référence (SSS : structures spatiales stables, CT : changements temporels, et RH : régions homogènes).

la fenêtre reste dans la “zone de changement”).

Le même comportement est observé avec les deux autres paramètres de texture. D’après ces résultats, avec un petit nombre d’images multi-dates (7 dans l’ensemble de données expérimentales), les dimensions spatiales appropriées sont par exemple, 5×5 ou 7×7 pour éviter l’effet de lissage des grandes fenêtres. Pour la détection de changements, si la disponibilité de données permet d’augmenter le nombre de dates, ces paramètres peuvent bénéficier de l’utilisation de tailles spatiales plus petites. Par exemple, lorsqu’une seule image est disponible, pour une erreur relative de 10% de l’estimée du niveau du mélange λ avec un ratio $\rho = 5$, la taille optimale de la fenêtre varie entre 71×71 pour $\lambda = 0.1$ et 21×21 pour $\lambda = 0.5$ [NICOLAS, 2002]. Avec 4 images multi-temporelles décorréelées, la même performance sera obtenue avec des volumes de respectivement $35 \times 35 \times 4$ et $11 \times 11 \times 4$. Pour 16 images, de volumes de $18 \times 18 \times 16$ et $5 \times 5 \times 16$ suffisent.

Enfin, les courbes COR sont utilisées pour comparer les trois attributs de texture proposés. Pour rendre la comparaison possible avec un seul seuil, nous prenons la valeur absolue du log-cumulant d’ordre 3 centré $|\widehat{\kappa}_{c3}| = |\widehat{\kappa}_3 - \Psi''(L = 3)|$ à la place de $\widehat{\kappa}_3$. Les courbes COR obtenues avec les volumes d’estimation de $5 \times 5 \times 7$ sont présentées en figure 4.4.4-b. Celles-ci montrent que le log-cumulant d’ordre 2 est le plus sensible aux changements temporels.



(a) Courbes COR du log-cumulant d'ordre 2, pour différentes tailles des fenêtres. (b) Courbes COR des paramètres de texture.

FIG. 4.17 – Evaluation des performances pour les paramètres de texture.

4.5 Conclusions

Pour conclure l'étude du comportement des détecteurs présentés dans les paragraphes 4.2, 4.3 et 4.4, nous présentons une comparaison des performances des attributs proposés (DCMT, DChMT et $\hat{\kappa}_2$) avec celles du test de vraisemblance généralisée (TVG) proposé dans [LOMBARDO and OLIVER, 2001] comme outil pour la détection de changements (cf. sec. 2.2.1). Le TVG calcule le rapport des moyennes arithmétiques et géométriques des moyennes locales aux différentes dates selon l'équation (2.2). Ce test fournit une mesure d'hétérogénéité [LOMBARDO and OLIVER, 1994] utilisée comme référence pour évaluer la sensibilité des attributs proposés à la présence de changements temporels ou de structures spatiales stables. Les quatre détecteurs sont appliqués, avec la même résolution spatiale (fenêtre 7×7), à l'ensemble de données de la région de Kourou ($N = 7$ images). Les courbes COR sont tracées pour des structures spatiales et pour des changements temporels, en utilisant leur régions de référence pour estimer les densités de probabilité conditionnelles de détection, et les régions de référence homogènes pour estimer les densités de probabilité conditionnelles de fausse alarme.

Les résultats présentés dans la figure 4.18 montrent que le DChMT et le TVG ont des performances similaires : les deux sont très sensibles aux changements temporels et légèrement affectés par la présence de structures spatiales. Comme attendu, le DCMT est sensible aux caractéristiques spatiales et n'est pas sensible aux changements temporels, tandis que le log-cumulant d'ordre 2 est sensible aux deux. En étant très sensible à l'en-

semble des discontinuités spatio-temporelles, les paramètres de texture 3D fondés sur les log-cumulants sont très utiles comme détecteurs de structures. Ils sont complémentaires des détecteurs DCMT, DChMT ou TVG qui reposent sur des approches plus conventionnelles et sont principalement sensibles soit aux caractéristiques spatiales soit aux changements temporels.

La fusion de ces trois types d'attributs rend possible la détection simultanée de structures spatiales et de changements temporels, chacun étant ainsi révélé par deux de ces attributs. Cette détection simultanée des changements et des structures spatiales est appliquée, dans la section 6.3, à l'analyse de la série multi-temporelle de la zone de Kourou (sec. 3.2) qui présente à la fois des zones de changements et un nombre important de structures spatiales stables.

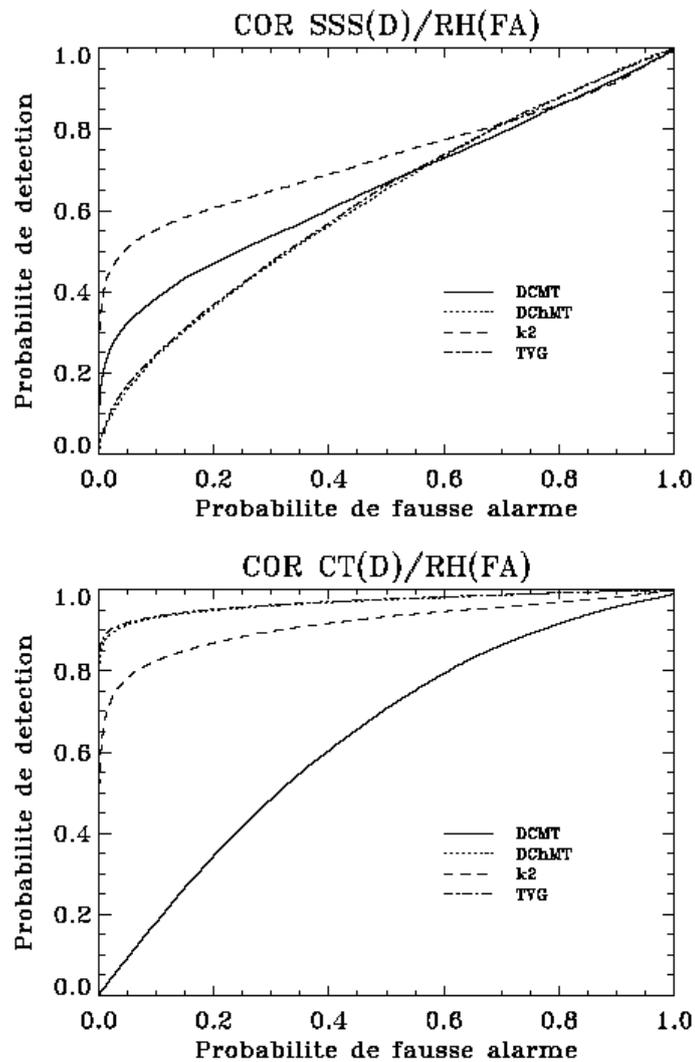


FIG. 4.18 – Comparaison de la sensibilité aux structures spatiales (dessus) et aux changements temporels (dessous) des attributs proposés (DCMT, DChMT et $\hat{\kappa}_2$) et du Test de Vraisemblance Généralisée.

Chapitre 5

Fusion d'informations

La fusion de données constitue un cadre formel dans lequel s'expriment les moyens et techniques permettant l'alliance des données provenant de sources diverses. Elle vise à l'obtention d'information de plus grande qualité ; la définition exacte de "plus grande qualité" dépendra de l'application.

L. Wald, *Some terms of reference in data fusion* [WALD, 1999]

Ce chapitre est consacré à la seconde étape de l'approche proposée pour analyser les données RSO multi-temporelles : la fusion d'informations.

L'utilisation conjuguée des données issues de différentes sources à travers la fusion d'informations a le potentiel de fournir des améliorations significatives par rapport à l'utilisation d'une seule source. Le terme de fusion d'informations est employé pour décrire une variété d'opérations de combinaison d'informations pour un éventail d'applications d'amélioration ou d'analyse d'images, ou pour des applications de détection ou de classification. La fusion d'informations est devenue une façon de décrire les procédés généraux de combinaison des ensembles des données entre-liées ou des connaissances qui sont fusionnées pour produire un résultat meilleur que le résultat obtenu avec les ensembles séparés. Une gamme d'opérateurs mathématiques a été employée pour réaliser ces procédés.

Dans le cadre de nos travaux, les informations à fusionner sont de forme numérique (les valeurs de différents attributs) et ont pour support les pixels des images traitées.

5.1 Intérêts de la fusion d'informations

Une gamme étendue d'applications utilise la fusion d'informations pour améliorer la performance des détections ou classifications automatiques. Parmi ces applications nous trouvons des applications de télédétection satellitaire ou aéroportée, des applications qui utilisent des systèmes d'information géographique (SIG), des applications médicales, industrielles ou militaires.

L'imagerie satellitaire ou aéroportée, utilisée pour des applications photogrammétriques, environnementales, ou d'évaluation des ressources terrestres peut être améliorée en combinant des données provenant de différents capteurs. Ces combinaisons permettent de raffiner la résolution spatiale ou spectrale d'un produit final "composite". Les images multi-temporelles, les images multi-spectrales ou les images multi-résolutions peuvent être combinées pour produire des images composées ayant des caractéristiques spectrales et spatiales meilleures que celles obtenues avec les images séparées. Deux étapes préliminaires sont souvent nécessaires pour pouvoir appliquer des méthodes de fusion d'informations aux données de télédétection : le recalage, c'est-à-dire l'alignement spatial des images et cartes d'une même zone dans un même système de coordonnées, et le mosaïquage, c'est-à-dire l'ajustement d'images non-chevauchantes adjacentes pour créer une image composée sur une plus grande zone. La reconstruction du relief et la mesure des dimensions spatiales d'objets imagés peuvent être également vues comme des cas particuliers de fusion de deux ou plusieurs images.

En incluant d'autres ensembles de données spatiales, tels que des modèles numériques de terrain, des données démographiques, ou différentes couches de données géographiques issues de systèmes d'information géographique, des nombreuses applications cartographiques peuvent bénéficier de la fusion d'informations.

5.1.1 Fusion d'informations dans le contexte image

La fusion d'informations, au sens initial du terme vise typiquement la combinaison des données bidimensionnelles ou tridimensionnelles sur des objets situés dans l'espace. Les cibles sur un champ de bataille, les avions dans l'air, les bateaux sur la surface de l'océan, ou les sous-marins dans l'océan sont des exemples de cibles représentées comme objets dans un modèle tridimensionnel de l'espace. Mais la fusion d'images, peut aussi impliquer l'association et la combinaison des ensembles complets de données bidimensionnelles

(images) ou tridimensionnelles (modèles numériques du terrain ou représentations spatiales des objets réels). La distinction est que la fusion d'informations des données image exige la représentation des données en chaque point, plutôt qu'en des points d'intérêt sélectionnés.

Les utilisations principales de la fusion d'informations dans des applications multi-temporelles englobent le recalage, la combinaison et le raisonnement. Le *recalage* comporte l'alignement spatial (géométrique) d'images des différentes dates et est une condition préalable pour la continuation du traitement. Il peut être réalisée au niveau brut (c'est-à-dire tous les pixels dans une image peuvent être mis en référence, avec une précision connue, aux pixels d'une autre image, ou aux coordonnées d'une carte) ou à des niveaux plus élevés, reliant des objets plutôt que les différents pixels. La précision avec laquelle les données ont été alignées, en fonction l'une de l'autre ou d'un système de coordonnées, est d'une très grande importance pour les applications de fusion. La *combinaison* s'opère sur des "couches" multiples recalées de données images pour dériver des produits composés en utilisant des opérateurs mathématiques qui effectuent, par exemple, des améliorations spatiales ou spectrales des images, des détections de changements ou des classifications. Le *raisonnement* est le processus par lequel des opérations de recherche intelligentes, souvent itératives, sont effectuées sur les données pour évaluer la signification de la scène entière, au niveau d'abstraction le plus élevé, ou au niveau des objets ou des événements contenus dans les données.

5.1.2 Techniques classiques de combinaison pour la fusion d'information

La littérature a adopté comme solutions de base pour la conception de systèmes de fusion d'information trois niveaux de représentation : pixel, caractéristique et décision [POHL and GENDEREN, 1998]. Comme le *pixel* est plutôt un support d'information et non un contenu d'information, il est préférable d'utiliser le terme de *données brutes* ou *mesures* [WALD, 1999]. La terminologie a été adoptée pour décrire l'étape de la chaîne de traitement dans laquelle se produit la combinaison des données de différentes sources.

Fusion au niveau brut

Au niveau le plus bas, la fusion au niveau brut utilise les données recalées de toutes les images pour réaliser des détections ou des classifications. Ce niveau a le potentiel d'obtenir la meilleure performance pour la détection de signal (si les erreurs de recalage sont minimales)

au coût du calcul le plus élevé. A ce niveau, les décisions de détection (concernant la présence ou l'absence d'un objet cible) sont basées sur l'information de toutes les sources en évaluant les données spatiales et spectrales de toutes les couches des données.

La fusion au niveau brut nécessite un recalage précis des différentes images avant d'appliquer l'opérateur de combinaison à chaque ensemble de pixels. La précision du recalage doit être au niveau sous-pixel pour éviter les erreurs. Puisque les données peuvent être acquises dans différentes géométries, le rééchantillonnage des images est généralement exigé pour atteindre la précision nécessaire avant de combiner les données brutes.

Fusion au niveau caractéristique

Au niveau intermédiaire, la fusion combine des caractéristiques des différents objets qui sont à détecter ou segmenter dans les différentes images. Les caractéristiques pour chaque objet sont extraites indépendamment dans chaque image ou dans des combinaisons d'images; avec ces caractéristiques un espace commun est formé pour être utilisé après pour la détection ou la classification des objets. C'est à ce niveau que se situe l'étape de fusion de l'approche *extraction-fusion* proposée dans cette thèse.

La fusion au niveau caractéristique peut réduire la demande de recalage, permettant la segmentation de chaque image ou le calcul de caractéristiques indépendamment des autres images. Les caractéristiques sont fusionnées dans un espace commun de décision seulement après qu'une association spatiale est faite pour déterminer si les caractéristiques ont été extraites à partir d'objets associés à la même région dans l'image. Dans certains cas, il est possible, voir préférable, de recalculer les caractéristiques extraites telles que les images d'attribut plutôt que de recalculer les images initiales. Par exemple, pour fusionner des caractéristiques provenant d'images RSO acquises sur des orbites croisées (ascendante et descendante), il est préférable de les calculer dans la géométrie radar initiale afin d'éviter les distorsions radiométriques et géométriques dues au rééchantillonnage.

Fusion au niveau décision

La fusion au niveau décision combine les décisions prises selon des chemins indépendants de détection ou de classification par différentes opérations mathématiques. Il existe deux types de décision dans les résultats de classification : les décisions *nettes* (un seul choix, optimal pour un critère donné) et les décisions *floues*, dans lesquelles l'incertitude de décision dans chaque chaîne de traitement est maintenue et combinée avec une mesure composée

d'incertitude.

Fusion à des niveaux multiples

En plus des ces trois niveaux classiques de fusion, d'autres solutions alternatives ou combinaisons ont été avancées. A un niveau encore plus haut que le niveau de décision, quelques méthodes ont été définies au *niveau scène* dans lesquelles les détections bas niveau sont utilisées pour confirmer les détections plus haut niveau.

Tous les types de fusion exposés précédemment sont utilisés pour combiner des images pour détecter/classifier certaines caractéristiques ou objets. Avant de présenter la méthode de fusion floue symbolique utilisée pour combiner les informations extraites avec les méthodes introduites au chapitre 4, nous rappelons les principes des classifications non-supervisées et supervisées. Nous introduisons aussi deux méthodes de classification, une non-supervisée et une supervisée, qui serviront de comparaison pour notre méthode de fusion floue.

5.2 Fusion/classification

Un photo-interprète, en essayant de classifier des données image, emploie des éléments d'interprétation visuelle pour identifier les groupes homogènes de pixels qui représentent les diverses classes thématiques. La classification automatique d'images utilise l'information "spectrale" représentée par des valeurs numériques dans une ou plusieurs images et essaye de classifier chaque pixel en se basant sur cette information. Dans un cas ou dans l'autre, l'objectif est d'affecter chaque pixel d'une scène à la classe correspondant au mieux à ses caractéristiques radiométriques et à son voisinage dans le cas de classifications contextuelles. L'image classifiée résultante est une carte thématique superposable aux images originales, chaque pixel appartenant à une classe particulière. En parlant de classes, il faut distinguer les classes d'entrée (classes *spectrales*) des classes de sortie (classes *thématiques*). Les classes spectrales sont des groupes de pixels qui sont uniformes, ou quasi-uniformes, du point de vue radiométrique dans les différents canaux des données. Les classes thématiques sont les catégories d'intérêt que le photo-interprète essaye d'identifier dans les images. La classification doit réussir à assortir les classes spectrales présentes dans les données aux classes thématiques d'intérêt.

Les approches habituelles de classification peuvent être décomposées en deux grandes familles en fonction de la démarche employée : les *classifications non-supervisées* et les *classifications supervisées*.

5.2.1 Classification non-supervisée

Pour les *classifications non-supervisées*, les classes spectrales sont d'abord groupées, en se basant seulement sur l'information numérique contenue dans les données, et sont ensuite assignées par le photo-interprète aux classes thématiques. Ces classifications sont obtenues par des algorithmes de clustering¹ pour déterminer des groupements statistiques ou des structures présentes dans les données. Habituellement, le photo-interprète indique combien de classes doivent être recherchées dans les données. En plus du nombre désiré de classes, le photo-interprète peut également indiquer des paramètres liés à la distance de séparation entre les classes et aux variances dans les différents canaux pour les différentes classes. Le résultat final de ce processus itératif peut comporter quelques classes que l'expert voudra combiner plus tard, ou quelques classes qui devraient être encore décomposées après. Ces deux post-traitements exigent une autre étape de l'algorithme de classification, supervisée ou non-supervisée. Ce type de classification est rarement exploitable sans l'intervention d'un superviseur, humain ou non.

Les méthodes de classification non-supervisées utilisent généralement un certain nombre d'itérations d'algorithme pour établir les classes thématiques à partir des images d'entrée avant d'appliquer les classes à l'image entière. La méthode de classification non-supervisée des *C-moyennes floues*, présentée dans l'annexe D, emploie des règles basées sur la logique floue, qui gère mieux le cas lorsque les frontières de classe sont imprécises ou progressives. La méthode C-moyennes floues crée un premier ensemble de classes prototypes, puis détermine un degré d'appartenance à chaque classe pour chaque pixel. Les degrés sont utilisés pour ajuster les attributions de classes et pour calculer le nouveau centre de la classe, et le processus se répète jusqu'à ce que la limite d'itération soit atteinte.

5.2.2 Classification supervisée

Dans les *classifications supervisées*, le photo-interprète identifie dans les images des échantillons représentatifs des différentes classes thématiques. Ces échantillons sont désignés

¹En français le mot "cluster" est souvent associé à la notion de nuage de points (ou nuées) et "clustering" à des méthodes qui séparent ces nuages.

comme *zones d'apprentissage*. Le choix des zones d'apprentissage appropriées est basé sur la connaissance experte du photo-interprète sur le secteur géographique présent dans les images. Ainsi, le photo-interprète *supervise* la caractérisation d'un ensemble de classes spécifiques. L'information numérique dans tous les canaux pour les pixels correspondants à ces zones est utilisée pour l'apprentissage. Une fois que les signatures pour chaque classe thématique sont déterminées, chaque pixel est comparé à ces signatures et la plus proche est reconnue comme la classe à laquelle le pixel appartient. Ainsi, dans une classification supervisée les classes thématiques (classes de sortie) sont d'abord identifiées, puis employées pour déterminer les classes spectrales qui les représentent.

Un exemple de classification supervisée est la méthode des Support Vector Machines (SVM) rappelé dans l'annexe E en se basant sur [SCHÖLKOPF *et al.*, 1999] et [VAPNIK, 1998].

Dans la section suivante nous présentons une approche interactive basée sur la fusion floue symbolique, employée ensuite pour combiner les attributs décrits au chapitre 4. En s'appuyant sur une forte interaction entre l'utilisateur et le système de fusion, cette approche, dont le résultat est ici une classification, ne s'apparente ni à un classifieur automatique, ni à un classifieur supervisée.

A titre indicatif, une comparaison entre l'approche de fusion floue interactive et des méthodes de type classification non-supervisée (C-moyennes floues) et supervisée (SVM) sera effectuée au chapitre 6, section 6.3. Ces deux méthodes (et les versions utilisées) n'ont pas été choisies afin d'optimiser les résultats, mais dans l'optique de comparer les démarches, une approche supervisée étant une manière différente d'introduire de l'information *a priori* sur les classes recherchées.

5.3 Fusion floue interactive d'attributs

Les deux méthodes présentées dans les sections précédentes (C-moyennes floues et SVM) permettent de réaliser la "fusion" d'informations numériques tels que les attributs présentés au chapitre 4, pour obtenir une classification (floue ou nette) des pixels de l'image.

Ces deux méthodes illustrent les deux grandes familles de classifieurs : les méthodes automatiques de type "clustering" ou supervisées de type réseaux de neurones ou champs Markov qui nécessitent une étape d'apprentissage. Entre une approche purement automatique dont les classes de sortie sont parfois éloignées des classes thématiques recherchées

et une approche supervisée qui exploite une information très forte issue des “vérités terrain”, nous avons préféré privilégier une troisième voie : une approche interactive basée sur la connaissance du comportement de chacun des canaux (attributs) vis-à-vis des classes recherchées. La théorie des sous-ensembles flous permet de coder cette connaissance sous forme de règle linguistique et de proposer à l'utilisateur un système de fusion interactif proche de son raisonnement. Nous avons donc choisi de poursuivre les travaux développés au LISTIC sur la fusion floue symbolique [VALET *et al.*, 2001] en développant une interface graphique destinée à mettre en œuvre cette fusion floue de façon interactive dans le contexte de l'analyse des données RSO multi-temporelles. Cette section présente tout d'abord les principes de la description linguistique des attributs et de leur fusion par des règles floues, puis les grandes lignes de l'interface homme-machine (IHM) développée à cet effet.

Le principe s'applique à la fusion de NbA attributs. Dans le cas d'un ajustement des paramètres par l'interface graphique, nous nous sommes limités à la fusion de deux ou trois attributs, mais les principes théoriques s'étendent sans difficulté à un plus grand nombre d'attributs. Par soucis de simplification, nous illustrons principalement le cas $NbA = 2$, et le cas $NbA = 3$ sera illustré dans les applications traitées avec trois attributs (cf. sec. 6.1 et sec. 6.3).

5.3.1 Description linguistique

Les attributs présentés au chapitre 4 sont agrégés grâce à la connaissance des photo-interprètes en utilisant la théorie des sous-ensembles flous, outil particulièrement adapté au codage d'expertise [ZADEH, 1965]. L'approche symbolique proposée permet d'impliquer directement les experts dans la façon de combiner les données d'entrée. La figure 5.1 illustre le principe d'un tel système. De plus, un fonctionnement quasi “temps réel” est recherché pour permettre une grande interactivité entre le système de fusion et l'expert qui ajuste les différents paramètres en fonction de la qualité de la détection obtenue.

Ce système de fusion se compose en deux étages. Le premier gère l'aspect symbolique du système qui est directement en relation avec les experts, le deuxième l'aspect numérique et “computationnel” de l'inférence floue, partie plus difficilement comprise par les experts, qui s'effectue de manière complètement transparente à leurs yeux.

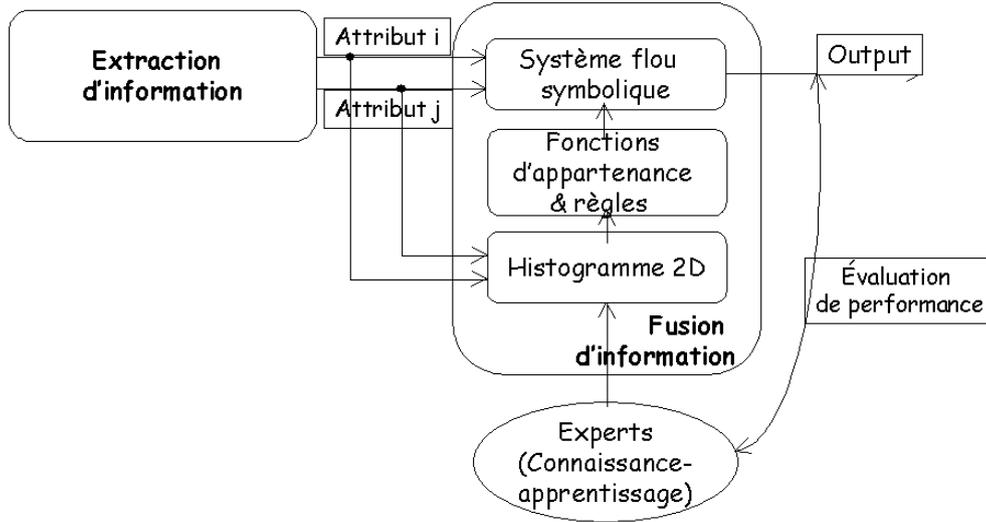


FIG. 5.1 – Principe d'un système de fusion floue coopératif appliqué à la détection de changements.

Représentation linguistique des attributs

Le premier étage du système concerne l'aspect symbolique de la fusion qui sert d'interface avec les experts. Ces derniers décrivent les attributs d'entrée à l'aide de mots de leur propre langage. Ces mêmes mots sont utilisés et combinés par le système. Afin de faire le lien avec le monde numérique des attributs, un sous-ensemble flou est associé à chacun des mots [ZADEH, 1971]. La figure 5.2 présente un exemple de description d'un attribut A_i à l'aide de trois mots :

$$\mathcal{L}_{A_i} = \{\text{petit}, \text{moyen}, \text{grand}\} \quad (5.1)$$

A chaque mot L correspond donc une fonction d'appartenance que l'on choisit de forme triangulaire (cf. fig. 5.2), notée $\mu_L(a_i)$, où a_i est la valeur de l'attribut A_i .

La représentation linguistique d'une valeur numérique est obtenue à l'aide des fonctions d'appartenance. Cela consiste, pour une entrée donnée, à déterminer le degré d'appartenance correspondant à chaque mot. Par exemple, pour la valeur a_1^* de l'attribut A_1 illustré figure 5.2, la description linguistique est la suivante :

$$\begin{aligned} D[\mathcal{L}_{A_1}](a_1^*) &= \mu_{\text{petit}}(a_1^*)/\text{petit} + \mu_{\text{moyen}}(a_1^*)/\text{moyen} + \mu_{\text{grand}}(a_1^*)/\text{grand} \\ &= 0.0/\text{petit} + 0.3/\text{moyen} + 0.7/\text{grand} \end{aligned} \quad (5.2)$$

$\mu_{\text{grand}}(a_1^*) = 0.7$ représente le degré d'appartenance de la valeur a_1^* au mot *grand*.

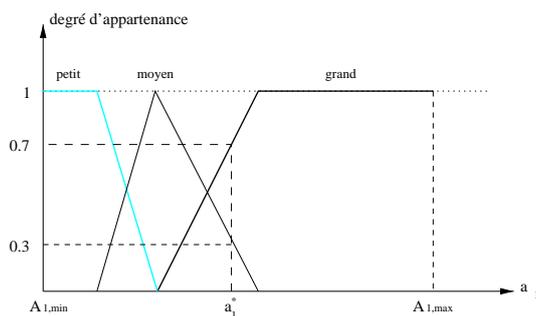


FIG. 5.2 – Exemple de partition floue associée à un attribut A_1 .

Ces fonctions d'appartenance sont choisies pour vérifier la propriété suivante : quelles que soient les valeurs d'entrée, la somme des degrés d'appartenance sur chaque mot est égale à 1 :

$$\sum_{L \in \mathcal{L}_{A_i}} \mu_L(a_i) = 1 \quad \forall a_i \in [-A_{i,min}, A_{i,max}], \quad \forall i \in \{1, 2\} \quad (5.3)$$

Cette propriété a deux avantages : d'une part elle réduit le nombre de paramètres à ajuster, d'autre part elle est facilement compréhensible par les utilisateurs.

Dans les cas où la sortie du système de fusion est une classification, les noms "thématiques" des classes constituent un ensemble de mots décrivant le résultat :

$$\mathcal{L}_{resultat} = \{S_k, k \in [1, NbC]\} \quad (5.4)$$

où NbC est le nombre de classes recherchées.

L'étape d'agrégation

Une fois que les descriptions floues des entrées ont été réalisées, l'étape suivante consiste à les fusionner dans le but d'obtenir une information concernant l'appartenance aux différentes classes S_k . Pour cela, on définit un ensemble de règles "SI-ALORS" de la forme :

SI A_1 EST *petit* ET SI A_2 EST *moyen*
ALORS la sortie APPARTIENT à la classe S_1 .

Lorsque le système de fusion ne comporte que deux entrées, les règles peuvent être rassemblées dans un tableau 2D. La figure 5.3 résume l'ensemble des règles qu'on utilise par exemple pour la détection de routes (cf. sec. 6.2) :

		Attribut A ₁		
		petit	moyen	grand
Attribut A ₂	petit			
	moyen		pas route	
	grand			route

FIG. 5.3 – Exemple de Tableau de règles pour la fusion de deux attributs de type “détecteur de route”.

Les zones grises de ce tableau représentent la classe *route*. Les autres représentent la classe *non-route*. Dans cet exemple, les deux classes de sortie sont décrites par les mots suivants :

$$\mathcal{L}_{resultat} = \{route, pas\ route\} \quad (5.5)$$

A chaque règle mettant en relation un ensemble de termes linguistiques de la prémisse $(L_{1,i}, L_{2,j}, \dots) \in \mathcal{L}_{A_1} \times \mathcal{L}_{A_2} \times \dots$, avec une classe de la conclusion $S_k \in \mathcal{L}_{resultat}$ (équation 5.5), on associe un degré de validité :

$$\mu_R(L_{1,i}, L_{2,j}, S_k) = \begin{cases} 1 & \text{si la règle est sélectionnée} \\ 0 & \text{sinon} \end{cases} \quad (5.6)$$

Les images résultats sont les degrés d'appartenance μ_{S_k} aux classes $S_k \in \mathcal{L}_{resultat}$. Ces degrés sont calculés au moyen de la règle de combinaison-projection qui s'écrit, pour deux attributs :

$$\mu_{S_k}(a_1, a_2) = \perp_{L_{1,i}, L_{2,j} \in \mathcal{L}_1 \times \mathcal{L}_2} \top \left(\top(\mu_{L_{1,i}}(a_1), \mu_{L_{2,j}}(a_2)), \mu_R(L_{1,i}, L_{2,j}, S_k) \right) \quad (5.7)$$

Dans cette expression, la \top norme est l'opérateur de combinaison et la \perp co-norme est l'opérateur de projection. Elle se généralise au cas de trois entrées et plus en utilisant la propriété d'associativité des opérateurs. Il existe un grand nombre de \top normes et de \perp co-normes [BLOCH, 1996]. Nous avons choisi d'utiliser les opérateurs proposés² dans [MAURIS *et al.*, 1996] :

²Ces derniers permettent d'obtenir une somme des degrés de sortie égale à 1 sous réserve que la relation R modélisant les règles soit surjective.

- $\top(a, b) = a * b$
- $\perp(a, b) = \min(a + b, 1)$

Les résultats obtenus par cette méthode se présentent sous la forme d'une classification floue. Par exemple, pour deux valeurs d'entrée a_1^* et a_2^* ayant les descriptions floues suivantes :

$$\begin{aligned} D[\mathcal{L}_{A_1}](a_1^*) &= 0.0/\text{petit} + 0.3/\text{moyen} + 0.7/\text{grand} \\ D[\mathcal{L}_{A_2}](a_2^*) &= 0.0/\text{petit} + 0.8/\text{moyen} + 0.2/\text{grand} \end{aligned} \quad (5.8)$$

le résultat de la fusion obtenu avec les règles illustrées dans la figure 5.3 aboutit à la classification floue suivante :

$$\begin{aligned} D[\mathcal{L}_{\text{resultat}}](a_1^*, a_2^*) &= \mu_{\text{pas route}}(a_1^*, a_2^*)/\text{pas route} + \mu_{\text{route}}(a_1^*, a_2^*)/\text{route} \\ &= 0.24/\text{pas route} + 0.76/\text{route} \end{aligned} \quad (5.9)$$

Ce résultat peut être interprété de la façon suivante : un pixel où les attributs A_1 , A_2 valent (a_1^*, a_2^*) appartient à la classe *route* avec un degré d'appartenance de 0,7 et à la classe *pas route* avec un degré de 0,3.

5.3.2 Pondération des règles

Une variante du système de fusion décrit dans la section précédente a été développé dans le cadre de cette thèse. Afin de réduire le nombre de paramètres ajustés par l'utilisateur, nous proposons une version semi-supervisée où la détection des règles se fait par apprentissage.

Le principe est d'utiliser une base de règles pondérées dont les coefficients appartiennent à l'intervalle $[0, 1]$. En ne faisant apparaître que deux attributs pour alléger les notations, l'équation (5.6) se transforme en :

$$\mu_R(L_{1i}, L_{2j}, S_k) = w_{ijk}^* \quad (5.10)$$

où w_{ijk}^* est la pondération de la règle qui relie le couple de mots (L_{1i}, L_{2j}) et la classe S_k . Pour calculer les pondérations de chacune des règles, nous proposons les *histogrammes* (2D, dans le cas de deux attributs) des points d'entrée $(a_1, a_2) \in A_1 \times A_2$, conditionnellement aux classes S_k . A partir des fonctions d'appartenance aux attributs A_1 et A_2 , on détermine ensuite le quadrillage correspondant aux intersections entre fonctions d'appartenance et on intègre chaque histogramme conditionnel sur chacune des cellules (fig. 5.4).

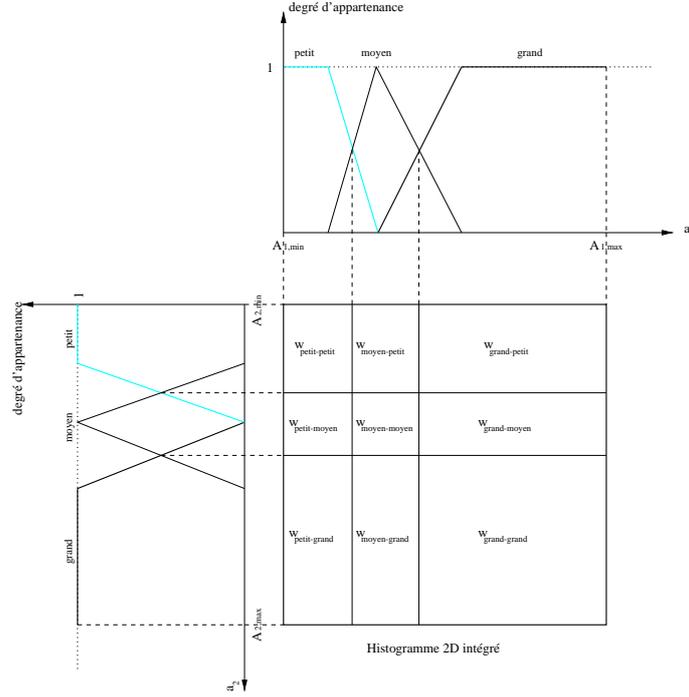


FIG. 5.4 – Cellules d'intégration d'un histogramme 2D correspondant à une partition floue.

Après l'intégration des histogrammes, on a obtenu les pseudo-pondérations w_{ijk} . Pour chaque classe S_k on cherche alors le maximum :

$$w_{max_k} = \max_{(i,j) \in \mathcal{L}_{A_1} \times \mathcal{L}_{A_2}} (w_{ijk})$$

pour normaliser les pondérations de la façon suivante :

$$w_{ijk}^* = \left(\frac{w_{ijk}}{w_{max_k}} \right)^2 \quad (5.11)$$

De cette manière, on donne la pondération 1 à la règle correspondant au domaine ayant le plus de points dans l'histogramme. Nous avons choisi une loi quadratique pour diminuer les pondérations des règles qui correspondent aux régions où l'histogramme a des valeurs insignifiantes.

Pour la classe "de rejet" S_k^* , pour laquelle on ne dispose pas de zone d'apprentissage, les pondérations w_{ijk}^* sont calculées de manière à satisfaire la relation :

$$\sum_k w_{ijk} = 1, \quad \forall(i, j) \quad (5.12)$$

Lorsque le nombre de classes de sortie est $NbC = 2$, il suffit d'intégrer l'histogramme conditionnel de la classe recherchée S_1 pour déterminer les poids w_{ij1} , en appliquant l'équation (5.12).

Lorsque le nombre de classes résultat est supérieur à deux, la détermination des poids de la dernière classe S_k^* par $1 - \sum_{k \neq k^*} w_{ijk}$ peut conduire à des pondérations négatives. Dans ce cas, on choisit de renormaliser de la façon suivante :

$$w_{ijk}^* = 0 \text{ et } w'_{ijk} = \frac{w_{ijk}}{\sum_k w_{ijk}} \quad (5.13)$$

de manière à conserver l'égalité (5.12).

5.3.3 Interface Homme Machine

L'aspect interactif du système de fusion floue proposé vise à faire participer les photo-interprètes dans la détection en utilisant leur expérience pour l'initialisation du système. Cette interactivité fonctionne également dans l'autre sens en donnant des résultats de sortie avec une mesure de qualité afin d'aider les interprètes à ajuster les paramètres du système.

Les paramètres du système sont de deux types : des paramètres fixes correspondant aux aspects numériques du traitement flou, transparents pour l'utilisateur, et des paramètres réglables correspondant aux fonctions d'appartenance et aux règles linguistiques du traitement flou. Ces derniers sont employés pour initialiser et, après une première détection, pour ajuster le système afin d'améliorer la détection.

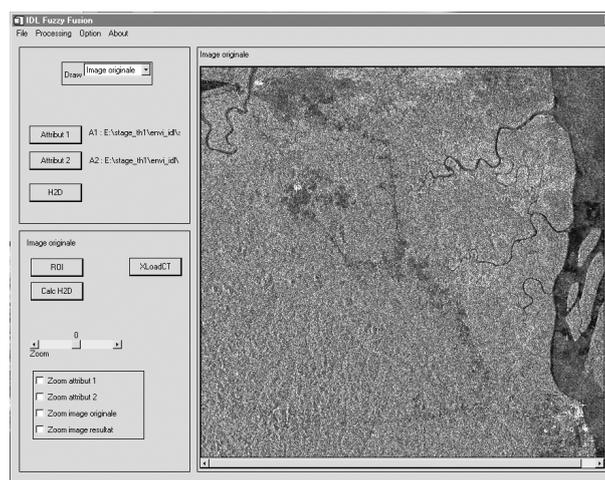


FIG. 5.5 – Interface graphique.

Le travail de l'utilisateur s'effectue en deux phases : une phase d'initialisation qui permet d'obtenir un premier résultat, suivie d'une phase de raffinement des paramètres.

Initialisation

Dans la phase d'initialisation, l'expert commence par tracer les zones de référence pour les classes de sortie et par donner l'ensemble de règles floues qui traduit sa connaissance. Les zones de référence sont dessinées par photo-interprétation dans une interface graphique dédiée à cette étape (fig. 5.5). Ce sont les zones où les experts sont sûrs de la nature de la région. Le but de cette étape est de choisir dans l'image les régions ayant les mêmes caractéristiques.

Par exemple lorsque deux attributs sont fusionnés, les histogrammes bidimensionnels (2D) permettent de représenter les distributions conditionnelles des deux attributs pour chacune des classes dessinées. Ceci donne une représentation graphique facilitant l'ajustement des fonctions d'appartenance associées à chaque mot (cf. fig. 5.6).

Après avoir fourni ces données d'entrée (les régions d'intérêt et les règles décrivant ces régions) le système de fusion possède assez d'informations pour réaliser une première détection. La figure 5.7 présente les trois images de degrés d'appartenance pour une classification en trois classes et la figure 5.9-a le résultat final après sélection de la classe ayant le maximum des degrés.

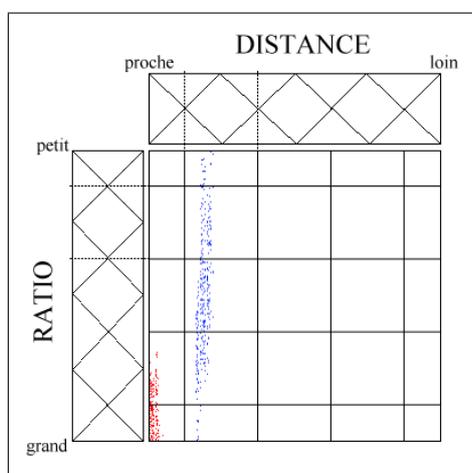


FIG. 5.6 – Exemple de nuages de points correspondants aux histogrammes 2D qui facilitent l'ajustement des fonctions d'appartenance pour deux attributs (distance et DChBT).

Ce premier résultat est obtenu sans réglage spécifique des fonctions d'appartenance qui sont triangulaires. Leur initialisation correspond à des valeurs modales équidistantes, illustrées dans la figure 5.6. Un meilleur ajustement des fonctions d'appartenance par l'utilisateur permet ensuite d'obtenir de meilleurs résultats.

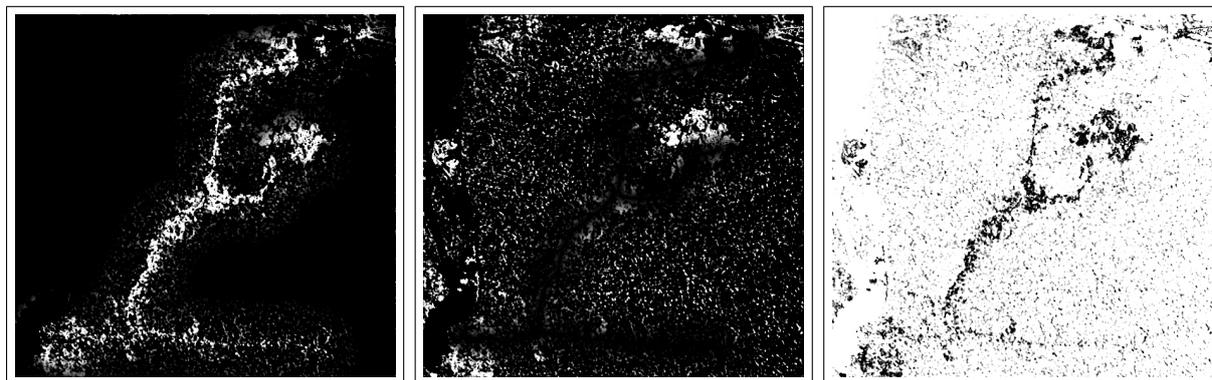


FIG. 5.7 – Résultat de fusion “3 classes” sans réglage fin : degrés d’appartenance aux 2 classes recherchées et à la classe de rejet

Ajustement des paramètres

La deuxième phase de la méthode consiste à faire évoluer les paramètres pour améliorer la détection conformément à l’évaluation qualitative des photo-interprètes. Cette étape est nécessaire car les attributs d’entrée ont une dynamique différente selon les zones de changements. Ce réglage doit être effectué facilement par l’utilisateur. Tous les paramètres ajustés peuvent être modifiés dans une fenêtre de l’interface graphique.

Pour positionner à leur convenance les règles et les fonctions d’appartenance, les utilisateurs ont la possibilité de déplacer les lignes horizontales et verticales sur l’image des histogrammes 2D ; les nouvelles intersections entre les fonctions d’appartenance sont ainsi calculées automatiquement. La figure 5.8 illustre un réglage affiné et la figure 5.9-b le résultat obtenu avec ce réglage qui est meilleur que celui de la figure 5.9-a (disparition de nombreuses fausses détections).

Si des zones de référence ont été tracées, cette amélioration de performances peut également être mesurée de façon quantitative à l’aide de courbes COR réalisées en seuillant les images de degré d’appartenance aux classes recherchées.

5.4 Conclusion

Le système interactif de fusion symbolique, présenté dans ce chapitre, joue un rôle central dans la stratégie *extraction-fusion* proposée pour l’analyse de données RSO multi-temporelles. Il facilite le dialogue avec l’expert ou l’utilisateur en leur permettant d’intégrer les informations *a priori* avec leur propre langage, ce qui est important et novateur dans le

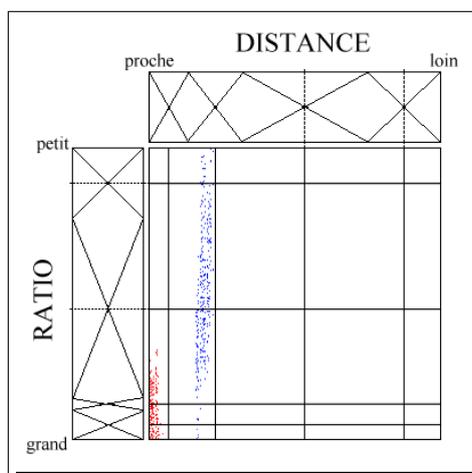


FIG. 5.8 – Réglage fin des règles et des fonctions d'appartenance de la figure 5.6.

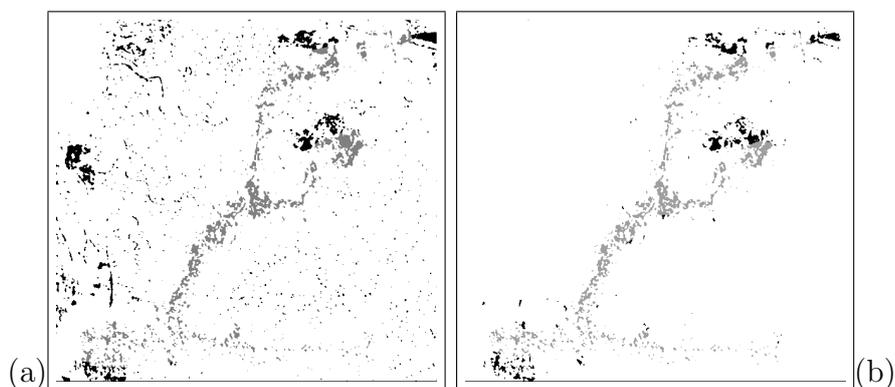


FIG. 5.9 – Résultats de fusion “3 classes : (a) avant ajustement fin ; (b) après ajustement.

contexte opérationnel. L'interactivité de l'étape de réglage permet d'affiner le positionnement des fonctions d'appartenance en jugeant des résultats de fusion obtenus sur de petites zones de l'image. Les règles qui relient la description symbolique des attributs aux classes thématiques recherchées peuvent être fournies par l'utilisateur ou apprises dans version semi-supervisée proposée section 5.3.2. Lorsque l'utilisateur est satisfait du résultat, l'ensemble du paramétrage est enregistré et la fusion peut ensuite être étendue à la totalité des données.

Chapitre 6

Applications

Dans ce chapitre nous présentons trois exemples d’analyse d’images RSO multi-temporelles sur les jeux de données présentés au chapitre 3. Ces trois exemples sont représentatifs des grandes classes d’applications présentées au chapitre 2. Nous appliquons la stratégie *extraction-fusion* en utilisant les opérateurs d’extraction et les méthodes de fusion d’informations développés dans les chapitres 4 et 5 respectivement.

Le premier exemple est une détection de changements classique. Elle est réalisée sur des paires d’images, sur lesquelles nous calculons plusieurs attributs que nous fusionnons ensuite selon différentes configurations. Une première détection de changements est faite en fusionnant l’attribut de contraste DChBT (sec. 4.3.1) et un attribut d’information *a priori* obtenu à partir d’une carte. L’apport d’un troisième attribut, le log-cumulant d’ordre 2 $\tilde{\kappa}_2$, est également présenté sur cette application.

Le deuxième exemple utilise la redondance entre des paires d’images RSO pour améliorer la détection de structures, en l’occurrence des routes. L’utilisation de paires d’images RSO acquises sur des orbites croisées est également expérimentée. L’attribut utilisé est le détecteur de lignes (sec. 4.2.2).

Le dernier exemple illustre la recherche simultanée de structures spatiales stables et de changements multi-temporels. Les attributs retenus pour cette application sont : le détecteur de contours multi-temporels (DCMT, Sec. 4.2.4, le détecteur de changements multi-temporels (DChMT, sec. 4.3.2) et le log-cumulant d’ordre 2 ($\tilde{\kappa}_2$, sec. 4.4.3).

Sur ce dernier exemple dont les résultats sont de type “classification”, nous illustrons également l’intérêt de la fusion floue symbolique réalisée de façon interactive, par rapport à deux méthodes de classification : d’une part une classification automatique sans apport de connaissance, telle que la méthode des C-moyennes floues, et d’autre part une classifi-

cation supervisée, telle que le méthode de SVM (Machines à Vecteurs de Support) où la connaissance apportée par l’expert est introduite au niveau de l’apprentissage.

6.1 Détection de changements bi-temporels

Les techniques de détection de changements dans les données RSO peuvent être divisées en plusieurs catégories selon les secteurs d’utilisation. Les changements peuvent être détectés par des méthodes fondées sur le suivi temporel d’objets ou de caractéristiques stables de formes géométriques reconnaissables, ou sur l’analyse de “différences” temporelles entre les images RSO, ou encore sur l’utilisation conjointe de données RSO et d’autres sources d’information.

L’application décrite ci-après consiste à rechercher des petites zones de déforestation (abattis) situées à proximité des routes à des fins de cultures vivrières. Deux sources d’information sont disponibles [BUJOR *et al.*, 2001] :

1. des images RSO, présentées dans la section 3.1, qui fournissent, après analyse, l’information temporelle de “changement” (voir aussi fig. B.4 en annexe B),
2. une carte géographique, représentée figure 6.1-a, qui fournit une information a priori sur la proximité des routes.

Deux types de détection sont proposés à des échelles différentes :

- une “*micro-détection*” effectuée à pleine résolution des images initiales,
- une “*macro-détection*” obtenue à plus faible résolution.

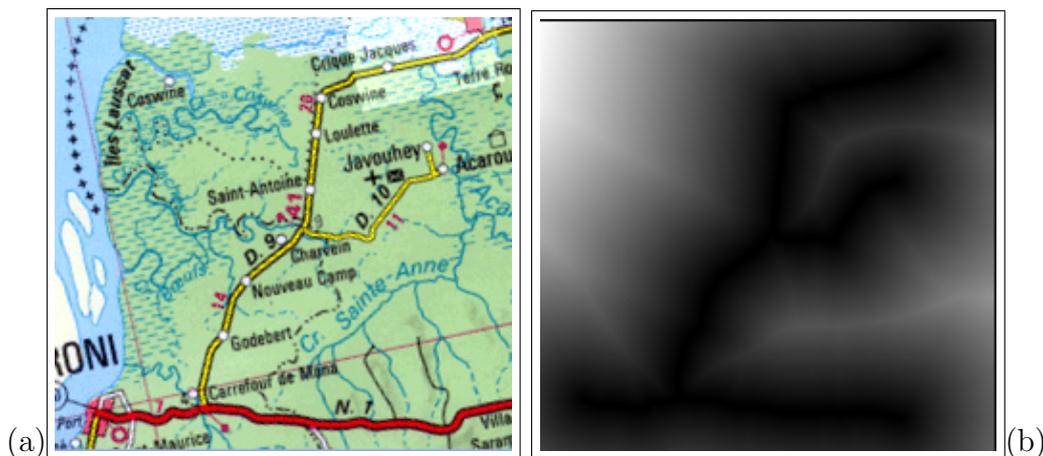


FIG. 6.1 – Information a priori : a) carte ; b) attribut “distance aux routes”.

6.1.1 Attributs

Micro-détection A l'échelle des micro-détections, l'attribut de changement le plus naturel est le DChBT (sec. 4.3.1), qui révèle les forts contrastes liés à la faible radiométrie après déforestation. Cet attribut est calculé en appliquant un filtre moyennneur bidimensionnel sur les deux images initiales et en calculant le ratio normalisé entre les radiométries moyennes pour chaque pixel selon l'équation (4.23). Afin d'avoir une bonne représentation et de garder le sens de variation, le résultat est codé selon l'équation (4.24).

Macro-détection Pour les images RSO, la densité de probabilité du ratio ν conditionnellement aux moyennes μ_n et $\mu_{n'}$ dépend seulement du nombre d'échantillons moyennés. L'hypothèse testée est "pas de changement". Sous cette hypothèse, la variable aléatoire *DChBT* suit la loi de distribution dérivée de la d.d.p.c. de ν avec $\mu_n = \mu_{n'}$.

La concordance entre les données expérimentales et la loi théorique est évaluée à l'aide du critère du χ^2 :

$$\chi^2 = \sum_{k=1}^K \frac{(\frac{m_k}{NbE} - P_k)^2}{P_k} \quad (6.1)$$

où NbE est la dimension de l'échantillon d'entrée, K le nombre de classes de quantification des d.d.p. estimée et théorique, m_k le nombre d'échantillons dans chaque classe, et P_k la probabilité de chaque classe, donnée par la loi théorique. Ce critère est utilisé pour indiquer les zones à fort risque de changement.

L'attribut DChBT et la valeur du critère χ^2 sont illustrés figure 6.2.

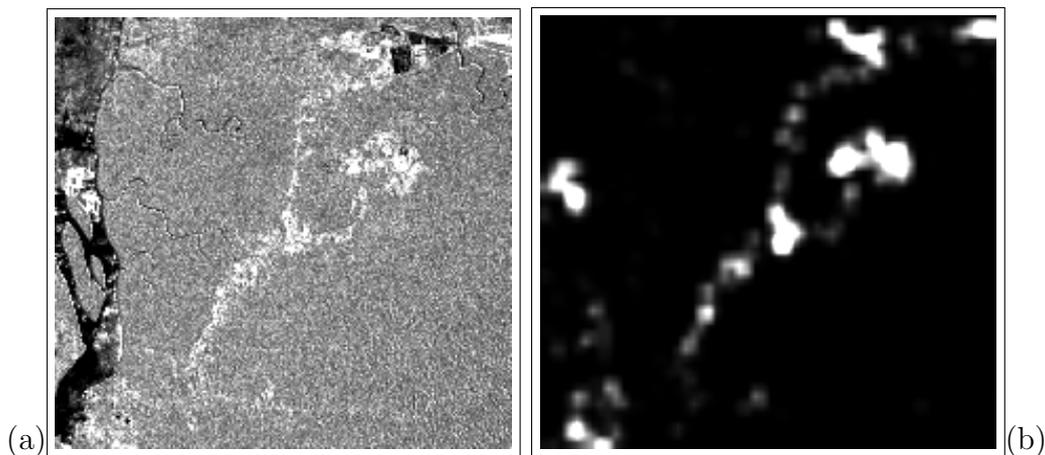


FIG. 6.2 – Attributs de changement : a) attribut DChBT ; b) valeur du critère χ^2 .

Attribut d'information *a priori* L'information *a priori* est la position des routes fournie par des cartes géographiques¹. Cette information est synthétisée dans un nouvel attribut en calculant pour chaque pixel la distance à la route la plus proche (cf. fig. 6.1-b).

6.1.2 Fusion

Les attributs présentés dans la section précédente sont agrégés grâce à la connaissance des photo-interprètes, par la méthode de fusion floue symbolique présentée en section 5.3. L'approche symbolique permet d'impliquer directement les experts dans la façon de combiner les données d'entrée. Le fonctionnement quasi *temps réel* de l'interface développée permet une grande interactivité entre le système de fusion et l'expert qui ajuste les différents paramètres en fonction de la qualité de la détection obtenue.

Le premier étage du système de fusion symbolique permet à l'expert de faire le lien entre le monde numérique des attributs et l'ensemble des mots utilisés en ajustant les fonctions d'appartenance [ZADEH, 1971]. La figure 6.3 présente une description des attributs *distance aux routes* et DChBT à l'aide de trois mots. Les deux ensembles de mots qui ont été choisis pour décrire ces attributs sont :

$$\begin{aligned}\mathcal{L}_{distance} &= \{proche, loin, très_loin\} \\ \mathcal{L}_{DChBT} &= \{reboisé, stable, déboisé\}\end{aligned}\tag{6.2}$$

Les différents paramètres des fonctions d'appartenance sont initialisés par l'expert en fonction de sa connaissance de l'application thématique et de la zone étudiée, et raffinés après essais sur une petite zone de l'image.

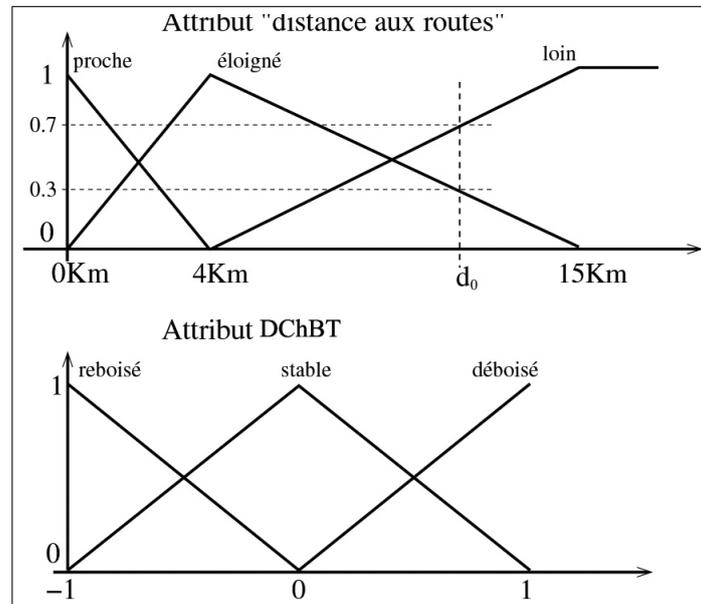
Après avoir défini le vocabulaire sur les entrées, les experts décrivent les différentes régions qu'ils recherchent. Dans cette application de type détection, l'ensemble de mots décrivant la sortie est :

$$\mathcal{L}_{resultat} = \{abattis, fond\}\tag{6.3}$$

La description des régions recherchées est réalisée par l'intermédiaire de règles floues telles que :

⋮

¹cartes d'échelle 1 : 500 000 réalisées et conçues par l'*Institut Géographique National* (N° 4702Y, 4701Y et 4703Y).

FIG. 6.3 – Partitions floues des attributs *distance aux routes* et DChBT.

SI distance aux routes EST proche
ET SI DChBT EST déboisé
ALORS le pixel APPARTIENT A abattis
 ⋮

Cette règle est représentée selon l'équation (5.6) par la relation suivante :

$$\mu_R(\text{proche}, \text{déboisé}, \text{abattis}) = 1$$

Si les mots ne sont pas liés par une règle alors $\mu_R = 0$.

Le deuxième étage du système de fusion réalise les opérations de fuzzification et d'inférence. La fuzzification de la valeur numérique d'un attribut d'entrée est réalisée grâce à la partition floue décrivant cet attribut. Par exemple, la valeur numérique de distance notée d_0 sur la figure 6.3 aboutit à la description linguistique suivante, après fuzzification :

$$\mu_{\text{distance}}(d_0) = 0.0/\text{proche} + 0.3/\text{loin} + 0.7/\text{très_loin} \quad (6.4)$$

L'inférence des propriétés des pixels est réalisée au moyen de la règle de combinaison-projection de Zadeh appliquée à des grandeurs symboliques [ZADEH, 1965], [DUBOIS *et al.*, 1999] selon l'équation (5.7). Le résultat de cette fusion se présente également sous la forme d'une description floue. Par exemple pour le pixel situé en (x,y)

on obtient :

$$\text{Pixel}(x, y) = 0.70/\text{abattis} + 0.30/\text{fond} \quad (6.5)$$

Ce résultat apporte une gradation sur l'appartenance d'un pixel aux différentes classes.

Cette démarche a été appliquée pour réaliser deux fusions différentes afin de détecter les abattis aux deux échelles auxquelles travaillent couramment les thématiciens. L'attribut DChBT utilisé pour les micro-détections est remplacé par la mesure du χ^2 pour les macro-détections.

La même démarche a été également appliquée en ajoutant aux attributs précédents (DChBT et *distance-aux-routes*) un nouvel attribut de type texture, le log-cumulant d'ordre 2 $\tilde{\kappa}_2$, défini dans la section 4.4. L'objectif de cette troisième fusion est d'apporter l'information issue des images RSO sous la forme de deux paramètres différents, l'un sensible au contraste entre deux dates, l'autre à la présence d'une texture. La description de ce troisième attribut est faite avec l'ensemble de mots suivants :

$$\mathcal{L}_{\tilde{\kappa}_2} = \{nil, \text{tres_bas}, \text{bas}, \text{moyen}, \text{haut}\}$$

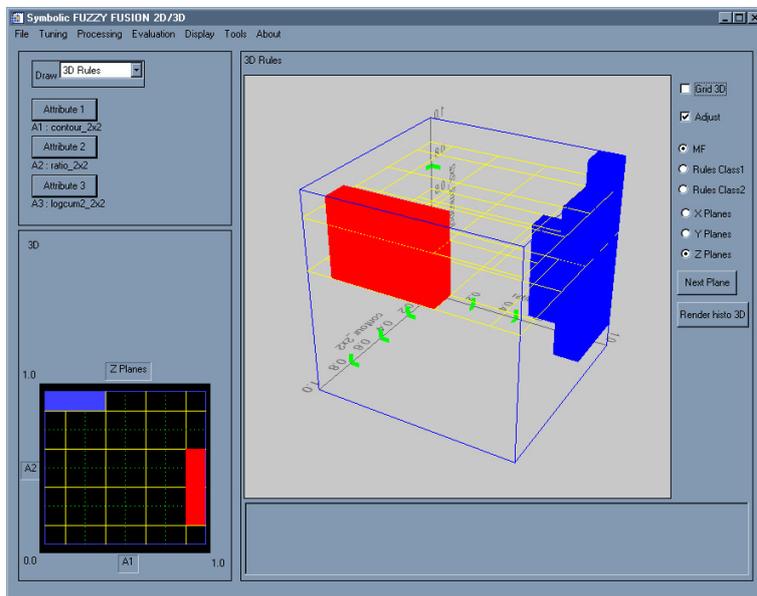


FIG. 6.4 – Interface Homme-Machine.

Les trois fusions réalisées pour cette application exploitent les fonctionnalités de l'Interface Homme-Machine (IHM) développée afin d'introduire interactivement la connaissance

experte. L'IHM contient un espace de représentation 2D ou 3D, selon le nombre d'attributs fusionnés, où chaque axe correspond à un attribut. Les paramètres linguistiques et les règles sont facilement placés directement dans cet espace de représentation. La partition floue de chaque attribut est initialisée par équirépartition des valeurs modales. A chaque règle correspond alors une cellule ou un sous-cube modifiable par l'utilisateur (fig. 6.4). Lors des ajustements, la cohérence de l'ensemble des fonctions d'appartenance décrivant les symboles impliqués est automatiquement assurée. Afin d'aider les experts dans l'ajustement, différents nuages de points correspondant aux régions d'intérêt (désignées par les experts ou données par des masques) peuvent être représentés dans l'espace d'attribut sous forme de distributions conditionnelles 2D ou 3D.

6.1.3 Résultats

Cette approche est illustrée sur la détection de zones d'abattis en Guyane française en utilisant la série St-Laurent du Maroni (sec. 3.1) des images RSO multi-temporelles fournies par les satellites ERS-1 et ERS-2. Le but est d'obtenir une segmentation des principaux abattis ou d'analyser des scènes entières afin de détecter les zones ayant un risque fort de présence d'abattis.

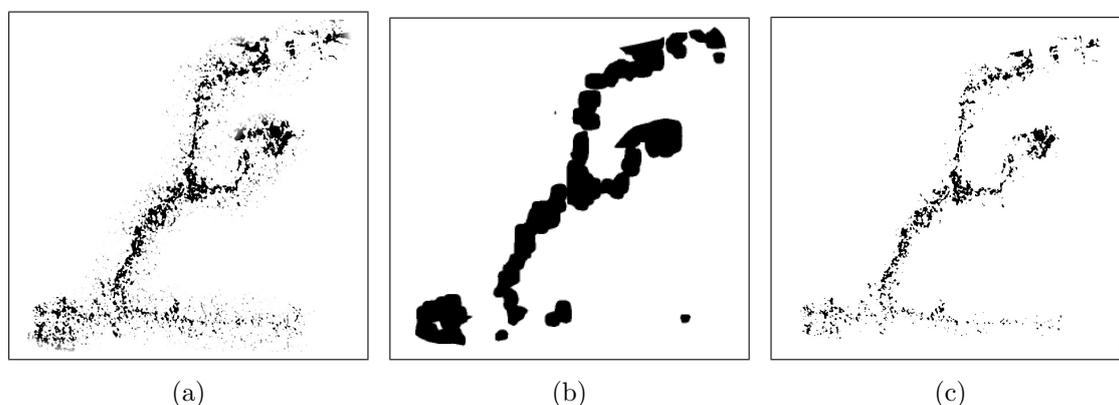


FIG. 6.5 – Résultats de détection de changements de type *abattis* obtenus par fusion de 2 attributs à l'échelle microscopique (a), à l'échelle macroscopique (b) et par fusion de 3 attributs (c).

Le résultat de la fusion de deux attributs à l'échelle microscopique est donné en figure 6.5-a où chaque pixel est affecté à la classe ayant le plus fort degré d'appartenance.

Cette fusion est exécutée à pleine résolution afin d’obtenir une segmentation des principales parcelles déforestées.

A l’échelle macroscopique, nous utilisons le critère du χ^2 à la place de l’attribut DChBT. Le calcul est exécuté en prenant des fenêtres d’analyse de 80×80 pixels sur lesquelles la distribution du ratio est estimée. Le critère du χ^2 résultant est calculé par pas de 40 pixels, puis interpolé pour avoir la même taille que l’image initiale. Le résultat final est obtenu par fusion avec l’attribut *distance aux routes*. L’image résultante (fig. 6.5-b) est constituée des deux zones : changement (en noir) et stationnaire (en blanc). Ainsi, la macrodétection permet de faire une détection grossière des zones de changements alors que la microdétection permet de réaliser une détection fine des abattis.

Par rapport à une thématique précise telle que la détection fine des abattis, nous sommes confronté au problème de l’“optimalité” du réglage des fonctions d’appartenance (cf. chapitre 5, figures 5.6 à 5.9), et au problème de la sélection des attributs donnant les meilleurs résultats.

Si une *vérité terrain* est disponible, un critère objectif d’évaluation des performances tel que les courbes COR, peut aussi être utilisé pour assister l’utilisateur dans l’ajustement du système de fusion. Pour les régions étudiées, des photos aériennes acquises en 1999 sont utilisées pour créer deux masques, un masque de fausse alarme M_{fa} , avec des zones non-déforestées, et un autre masque de détection M_d , avec les zones clairement identifiées comme déforestations (fig. 3.3).

Les histogrammes normalisés du degré d’appartenance à la classe “zone déforestée”, sur les zones M_d et M_{fa} , fournissent respectivement la densité de probabilité conditionnelle pour la détection $f_d(x)$ et la densité de probabilité conditionnelle pour la fausse alarme $f_{fa}(x)$. Pour un seuil de décision t , la probabilité de détection $P_d(t)$ et la probabilité de fausse alarme $P_{fa}(t)$ sont données par (4.22). Les courbes paramétriques $(P_d(t), P_{fa}(t))$ pour $t \in [0, 1]$ fournissent les courbes COR qui permettent de comparer les résultats obtenus.

Cette procédure d’évaluation permet d’apprécier quantitativement l’effet de l’ajustement du système de fusion. La figure ?? présente les courbes COR correspondant aux résultats obtenus avant et après ajustement (cf. fig. 5.9-a,b). Nous mesurons ainsi l’amélioration résultant d’un ajustement fait par les experts qui sont familiarisés avec la région d’analyse [CLASSEAU *et al.*, 1999] par rapport à un ajustement de type *équirépartition* des valeurs modales.

La même procédure peut être appliquée pour évaluer l’amélioration des performances résultant de l’utilisation du troisième attribut, qui apporte des informations sur les textures

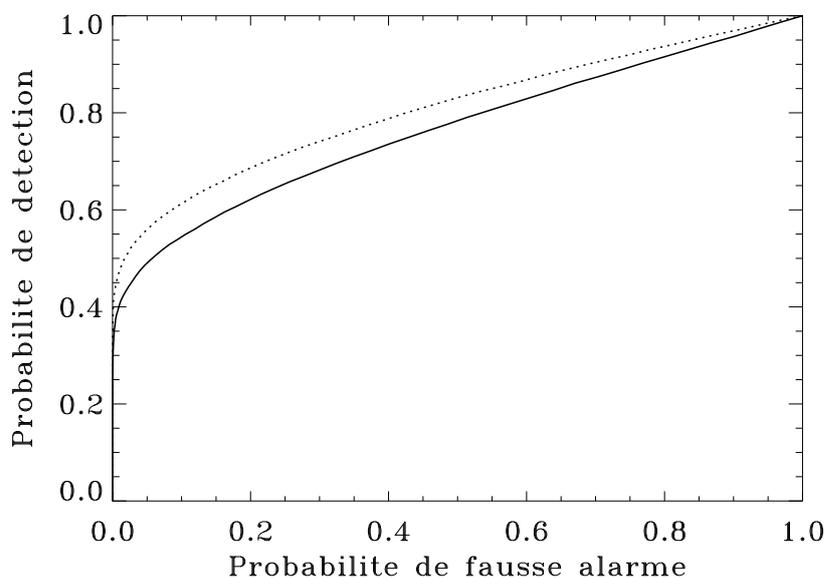


FIG. 6.6 – Evaluation des performances par courbes COR ; ligne continue : avant ajustement (fig. 5.9-a) ; ligne pointillée : après ajustement (fig. 5.9-b).

présentes dans les images. Le résultat de la fusion de deux attributs, DChBT et *distance aux routes*, est illustré dans la figure 6.5-a et celui de la fusion de trois attributs, DChBT, *distance aux routes* et $\tilde{\kappa}_2$, dans la figure 6.5-c. La figure 6.5-c montre une amélioration de la détection des abattis proches des routes, amélioration visible par une diminution du nombre de fausses détections par rapport à ce qui est obtenu avec deux attributs. Cette impression visuelle est confirmée par la comparaison des courbes COR présentées dans la figure 6.7.

La présentation et le vocabulaire employés ci-dessus pour décrire le mécanisme de construction des courbes COR sont ceux de l'approche probabiliste classique, bien que notre démarche repose sur une approche par sous-ensembles flous. En pratique, le seuil de décision t correspond au niveau α d'une α -coupe du sous-ensemble flou associé à la classe recherchée.

Procéder ainsi évite de recourir à un vocabulaire nouveau pour décrire un outil qui existe déjà. En fait, la démarche suivie ici est identique à celle présentée au chapitre 4 à propos des détecteurs. Elle revient à considérer les degrés d'appartenance à la classe recherchée comme les sorties d'un détecteur au sens ordinaire du terme.

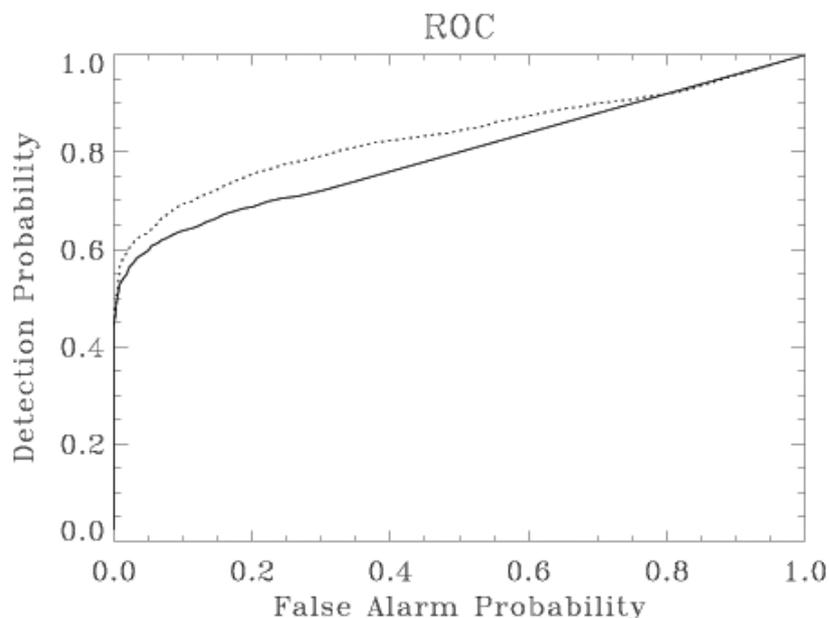


FIG. 6.7 – Evaluation des performances par courbes COR ; ligne continue : fusion de deux attributs (fig. 6.5-a) ; ligne pointillée : fusion de trois attributs (fig. 6.5-c).

6.1.4 Conclusion

L'application présentée dans cette section est typique des problèmes rencontrés lors de l'utilisation des images satellitaires. La détection de zones de déforestation nécessite de prendre en compte à la fois les mesures effectuées sur les images et des informations a priori provenant par exemple de cartes. Les objectifs des traitements vont du marquage de zones d'intérêt à la segmentation d'objets précis.

Les résultats obtenus illustrent l'intérêt des méthodes interactives pour les utilisateurs finaux. Grâce à une description symbolique de l'information et à un modèle de fusion fondé sur des règles floues, le traitement réalisé est proche du raisonnement des experts. Doté d'une interface graphique conviviale, le système est rapidement pris en main par le photo-interprète qui fait évoluer les paramètres de la méthode floue proposée. L'ajout d'outils de mesure de performance tels que les courbes COR et les matrices de confusion permet à l'utilisateur de tester rapidement différents choix d'attributs et d'affiner son paramétrage sur des critères quantitatifs. Il obtient ainsi des résultats conformes à ses attentes et validés par des mesures objectives.

6.2 Détection de structures spatiales stables

La deuxième application concerne la détection de structures linéaires. Les données proviennent de la série d'images du Cameroun (sec. 3.3) et couvrent la région située à l'Est de la ville de Douala. Dans un premier temps, nous nous intéressons à l'effet de la fusion multi-temporelle en comparant ses résultats avec ceux obtenus par une détection mono-temporelle. Dans un deuxième temps, nous étudions l'influence du choix des images d'entrée : images originales (codées sur 16 bits) ou images recalées (rééchantillonnées et codées sur 8 bits) ; images de la même géométrie (ascendantes ou descendantes) ou images avec des géométries différentes (une ascendante et une descendante). L'évaluation des performances repose, comme précédemment, sur la détermination de courbes COR. L'objectif est ici la détection de routes dans une zone de forêt tropicale. Cette application est importante, notamment pour la mise à jour automatique de cartes.

6.2.1 Fusion de détections vs. détection mono-temporelle

Pour calculer les attributs à fusionner, nous appliquons le détecteur de lignes (sec. 4.2.2) sur les deux images de même géométrie codées sur 16 bits (fig. 6.8). Les routes sont des structures linéaires sombres. Pour les détecter, il convient d'imposer la condition supplémentaire :

$$\bar{A}_0 > \bar{A}_1 \quad \text{et} \quad \bar{A}_2 > \bar{A}_1 \quad (6.6)$$

où \bar{A}_0 , \bar{A}_1 et \bar{A}_2 correspondent aux radiométries moyennes des sous-fenêtres de détection, avec les notations de la figure 4.5.

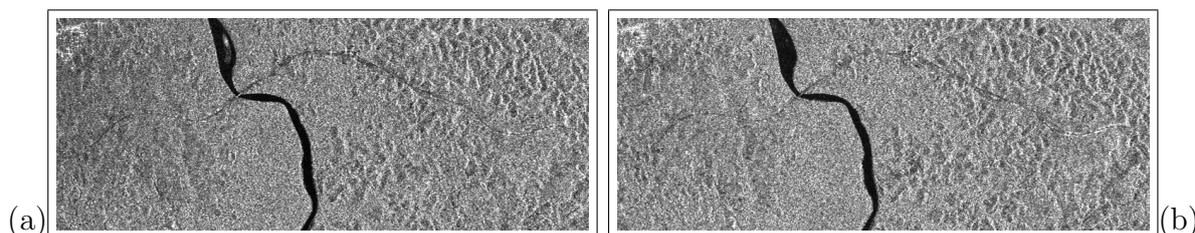


FIG. 6.8 – Images 16 bit acquises en orbite descendante : (a) image ERS-1, 4 décembre 1995 (orbite 22941, frame 3519) ; (b) image ERS-2, 2 février 1999 (orbite 19801, frame 3519).

Expérimentalement, l'utilisation d'un masque de 21×21 pixels, avec une zone centrale A_1 ayant 3 à 4 pixels de largeur, donne les meilleurs résultats du point de vue visuel

(fig. 6.9).

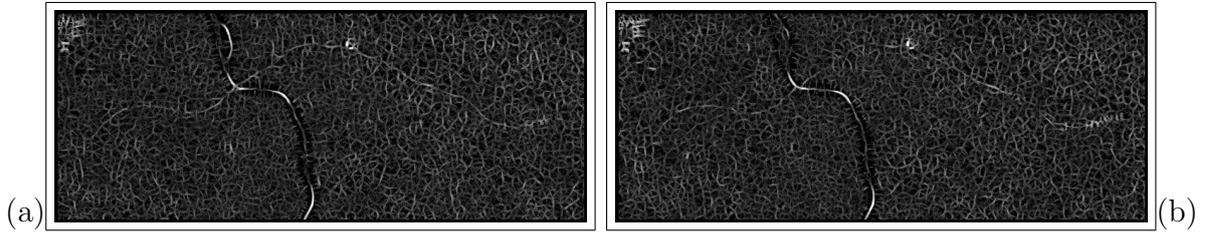


FIG. 6.9 – Sortie de l’opérateur de détection de lignes (a) image ERS-1 et (b) image ERS-2.

La fusion d’attributs résultant de l’application du détecteur de lignes aux différentes images est réalisée par le système de fusion floue présenté dans le chapitre 5, section 5.3. Le schéma de la fusion est donné dans la figure 6.11. Chacun des attributs d’entrée est décrit à l’aide de trois mots simples : $\mathcal{L}_A = \{faible, \text{moyen}, fort\}$. Les fonctions d’ap-

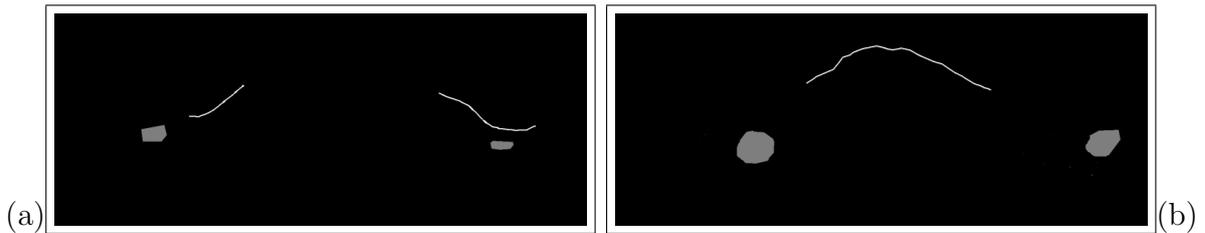


FIG. 6.10 – Zones de référence issues de vérité terrain. Portion de route en blanc, zone sans route en gris : (a) Masque d’apprentissage des régions *route* et *pas route*; (b) masque d’évaluation des performances.

partenance sont fixées en s’appuyant sur les nuages de points issus de zones de référence construites à partir de la vérité terrain fournie par des experts. Ces zones contiennent une portion de la route et une région où il n’y a aucune route (fig. 6.10-a). En utilisant l’IHM développée (sec. 5.3.3) nous calculons l’histogramme 2D de détection et de fausse alarme des deux attributs respectivement avec le masque “route”, et avec le masque “pas route”. L’observation de nuages de points dans l’espace des attributs met en évidence le fait que les classes de sortie sont relativement séparables dans le cas d’images acquises sous le même angle et sans rééchantillonnage.

Les deux versions de la méthode présentées dans la section 5.3 (c’est-à-dire la version interactive et la version semi-supervisée) sont appliquées afin de comparer leurs résultats. La version purement *interactive* nécessite de placer manuellement les fonctions d’appartenance

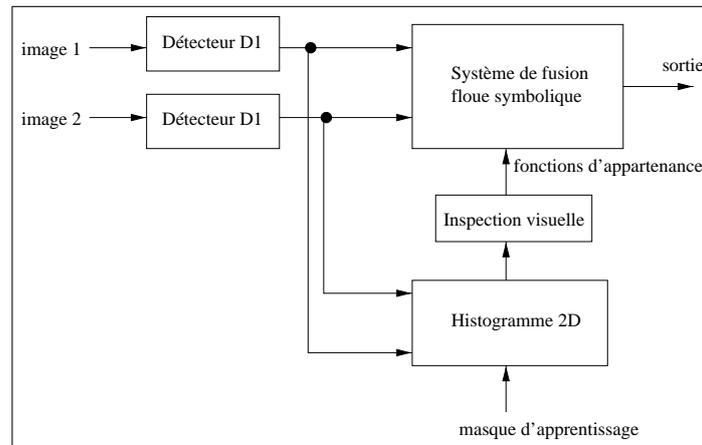


FIG. 6.11 – Fusion des résultats du détecteur de lignes dans les images ERS-1 et ERS-2.

et de sélectionner des règles binaires. La version *semi-supervisée* détermine automatiquement les règles avec leur pondération à partir des histogrammes conditionnels 2D. Dans le cas d'un problème de détection (2 classes) et d'une description des attributs à l'aide de trois mots, la version semi-supervisée peut également déterminer automatiquement les valeurs modales de la description symbolique des attributs à partir des valeurs médianes des histogrammes conditionnels.

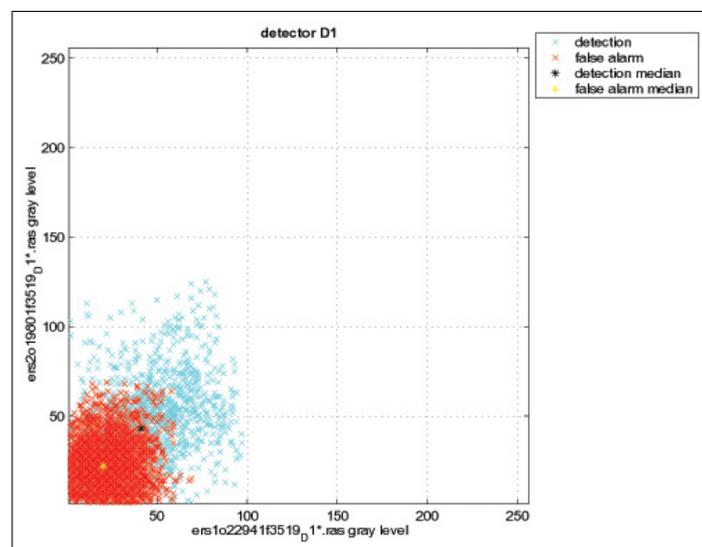


FIG. 6.12 – Histogramme 2D des résultats de détecteur de lignes sur les images ERS-1 et ERS-2.

Les résultats de la fusion, interactive ou semi-supervisée, sont présentés dans la figure 6.13. L'évaluation quantitative des performances par courbes COR est donnée en figure 6.14.

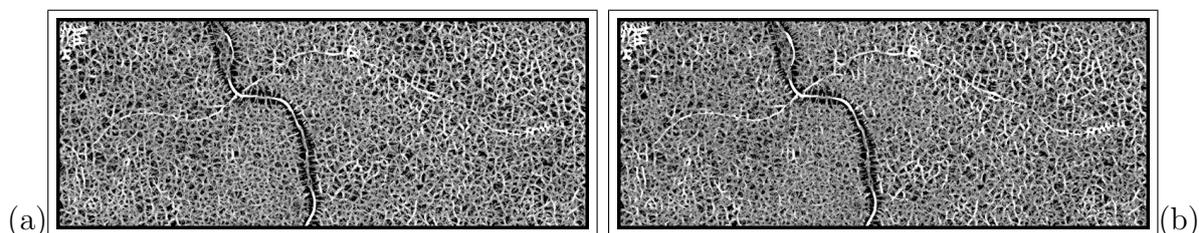


FIG. 6.13 – Résultats de la fusion de détections de lignes dans les images ERS-1 et ERS-2 : (a) fusion interactive, (b) fusion semi-supervisée.

Il apparaît que, pour une probabilité de fausse alarme inférieure à 9%, les meilleurs résultats sont obtenus par la fusion. Le fait qu'il y ait croisement des courbes COR pour les valeurs plus élevées de fausse alarme n'est pas gênant car, du point de vue opérationnel, le taux de fausse alarme doit rester faible pour que l'image résultat soit exploitable.

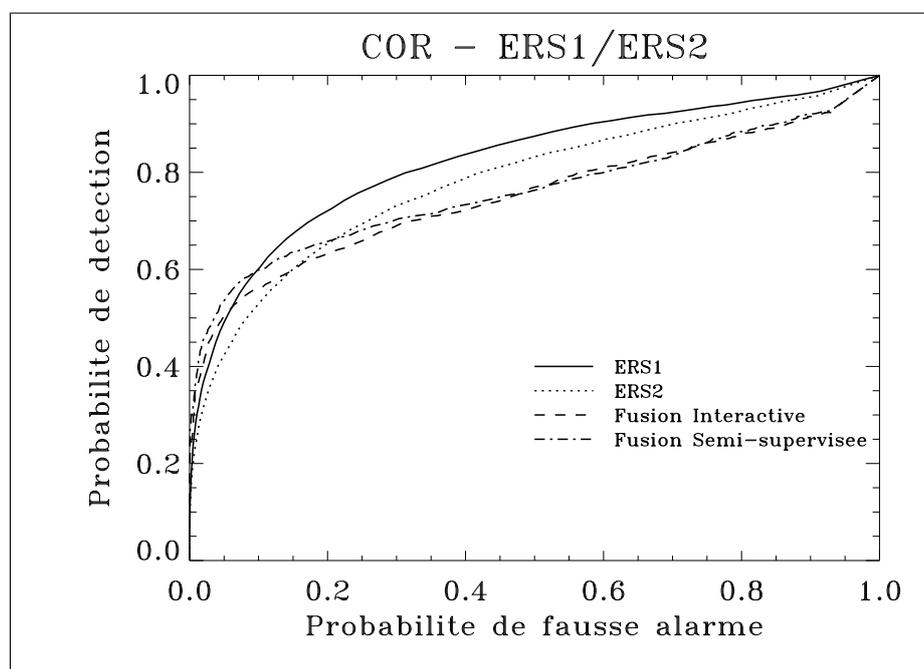


FIG. 6.14 – Evaluation des performances par courbes ROC pour la détection de structures linéaires : ERS-1, ERS-2, fusion interactive, fusion semi-supervisée.

6.2.2 Comparaison entre différents formats de données

La même démarche a été appliquée pour évaluer l'impact du format des données sur la qualité des résultats :

- deux images 16 bits (PRI = *Precision Image*) de la même orbite (descendante) ;
- deux images 8 bits de la même orbite (descendante), géocodées dans la géométrie d'une carte ;
- deux images 8 bits géocodées provenant d'orbites différentes (descendante et ascendante).

Les résultats de la fusion des images 16 bits ont déjà été analysés dans la section 6.2.1.

Cas de deux images, orbites descendantes, géocodées sur 8 bits

Les images 8 bits proviennent des images PRI qui ont été recalées dans la géométrie nord-sud. La technique de recalage consiste à sélectionner manuellement des points stables présents dans les deux images, à en déduire la transformation géométrique qui les relie et à recréer une nouvelle image sur la grille d'arrivée par interpolation.

Les images recalées sont présentées dans la figure 6.15. Les résultats obtenus avec le

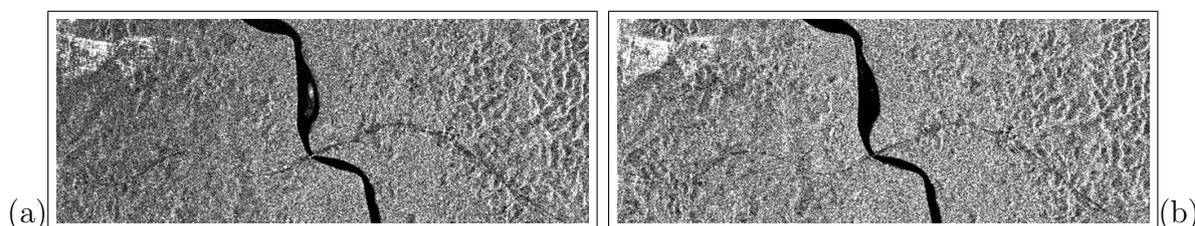


FIG. 6.15 – Images 8 bit acquises sur des orbites descendantes et recalées N-S : (a) image ERS-1, (b) image ERS-2.

détecteur de lignes sont présentés dans la figure 6.16. Les courbes COR de la fusion des résultats de détecteur de lignes dans les deux images (fig. 6.17) montrent que la fusion des réponses du détecteur de lignes n'améliore pas la détection.

Cas de deux images géocodées, acquises sur des orbites différentes (descendante et ascendante)

Le processus de recalage est plus difficile quand les images sont acquises selon des orbites différentes. Les déformations géométriques dues au relief (cf. annexe A) différent

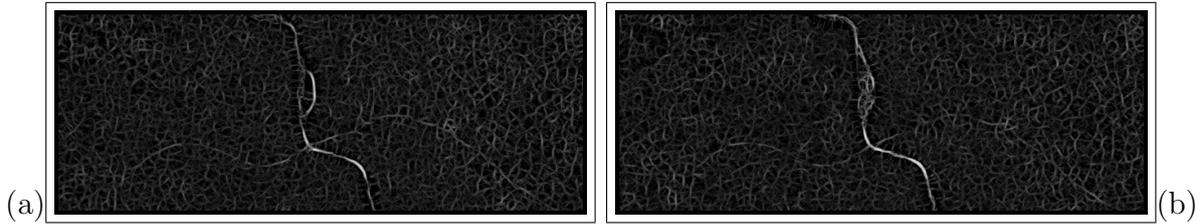


FIG. 6.16 – Images de sortie de l’opérateur de détection de lignes : (a) image ERS1- et (b) Image ERS-2.

d’une image à l’autre. Il est préférable de ne pas prendre de points stables dans les régions de montagne. Il reste alors peu de points stables disponibles, ce qui rend le recalage moins précis. Les images recalées sont présentées dans la figure 6.18.

Les images en sortie de l’opérateur de détection de lignes mono-temporel sont présentés dans la figure 6.19. Les courbes COR de la fusion des résultats du détecteur de lignes dans les deux images (fig. 6.20) montrent que la fusion de ces réponses n’améliore pas la détection.

Comparaison entre les trois configurations de fusion

Les courbes COR (fig. 6.21) montrent que la fusion des résultats de détection est la meilleure dans le cas de la fusion des images PRI (16 bits) de la même géométrie. La fusion des images recalées issues de la même géométrie reste meilleure que celle des images recalées provenant de géométries différentes. Ceci est vraisemblablement dû aux difficultés du recalage.

6.2.3 Conclusion

Cette étude a permis de comparer différentes configurations pour la détection de structures linéaires telles que des routes. L’élément de base est l’opérateur de détection de lignes adapté à la nature multiplicative du speckle, décrit au 4.2.2.

Nous avons premièrement expérimenté la méthode de fusion sur des images PRI (16 bits). La fusion des réponses du détecteur de lignes dans des différentes images RSO améliore la détection pour un taux bas de fausse alarme, c’est-à-dire que si l’application de détection de routes utilise un seuil bas de fausse alarme, la fusion est meilleure. Si elle utilise un seuil haut de fausse alarme, le résultat du détecteur de lignes dans la meilleure

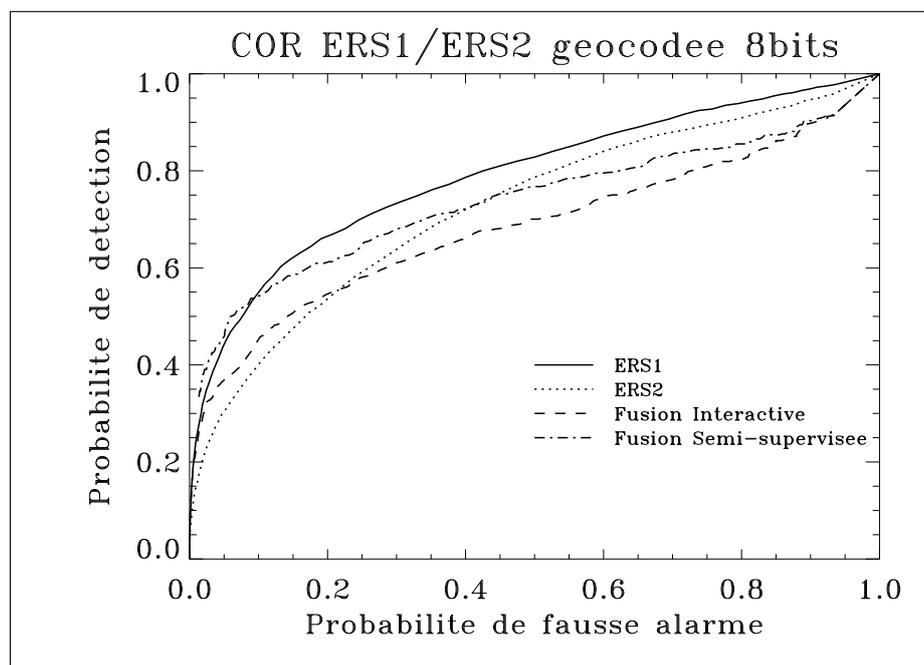


FIG. 6.17 – Courbes COR pour la fusion de la réponse du détecteur de lignes dans les images ERS-1 et ERS-2, géocodées 8 bits.

image est préférable. Les résultats obtenus dans d'autres configuration sont moins bons. La meilleure configuration de fusion de sorties de détecteur de lignes est celle où les images PRI proviennent de la même géométrie et n'ont pas subi de rééchantillonnage et de compression de dynamique sur 8 bits. En fait, le passage à 8 bits entraîne une distorsion de la distribution des données. L'interpolation contribue elle aussi à la distorsion de la statistique des données.

Du point de vue méthodologique, nous avons mis en œuvre les deux versions (interactive ou semi-supervisée) de la méthode de fusion proposée. Nous avons ainsi montré qu'il est possible de réaliser, sur ce type d'application, un apprentissage des fonctions d'appartenance et des règles. Les résultats sont très proches de ceux obtenus par un bon ajustement interactif du système de fusion. Les performances équivalentes s'expliquent par le fait que la même information est injectée dans le système de fusion soit sous la forme de nuages de points d'apprentissage dans la version semi-supervisée, soit sous la forme d'un ajustement manuel des règles, l'utilisateur pouvant s'appuyer sur la visualisation de zones de référence dans l'espace des attributs.

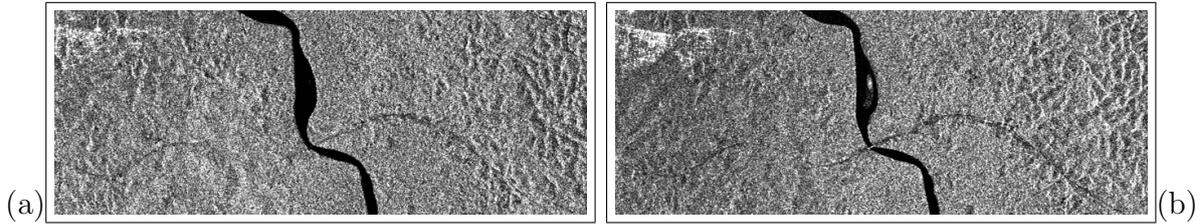


FIG. 6.18 – Images 8 bit recalées N-S : (a) image ERS-1 — orbite ascendante, (b) image ERS-1 — orbite descendante.

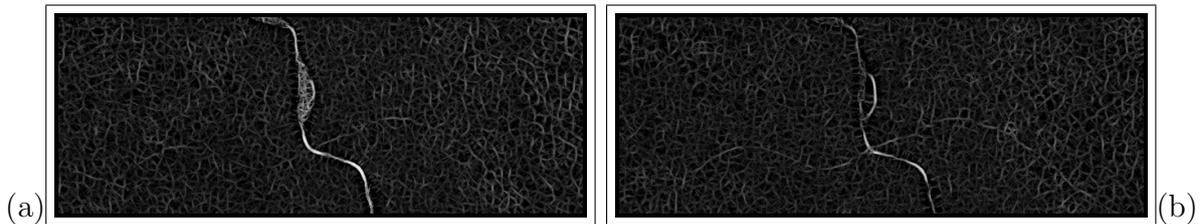


FIG. 6.19 – Résultats du détecteur de lignes dans les images (a) ERS-1 — orbite ascendante, et (b) ERS-1 — orbite descendante.

6.3 Détection simultanée de structures spatio-temporelles

En complément des deux exemples précédents, la troisième application concerne la détection simultanée de deux phénomènes observables dans les images RSO multi-temporelles : les changements temporels et les structures spatiales stables. Les *changements temporels* (*CT*), correspondent aux modifications physiques de la couverture terrestre se traduisant par des variations radiométriques (évolutions de cultures, zones inondables, etc.). Les *structures spatiales stables* (*SSS*) correspondent à des structures ponctuelles comme les bâtiments, aux structures linéaires telles que les routes ou les rivières étroites, ainsi qu'à des frontières d'objets surfaciques comme les lacs, les rivières larges, etc. Ces structures introduisent des discontinuités spatiales qui sont difficilement détectables lorsqu'une seule image est disponible à cause de la présence du speckle. Lorsque les structures spatiales sont stables temporellement, la redondance des informations provenant des différentes images rend la détection plus facile. Lorsque les structures spatiales sont instables temporellement, du fait, par exemple, des déplacements de leurs frontières ou de leur disparition dans certains images, elles peuvent appartenir aux deux classes d'intérêt : SSS ou CT. Puisque

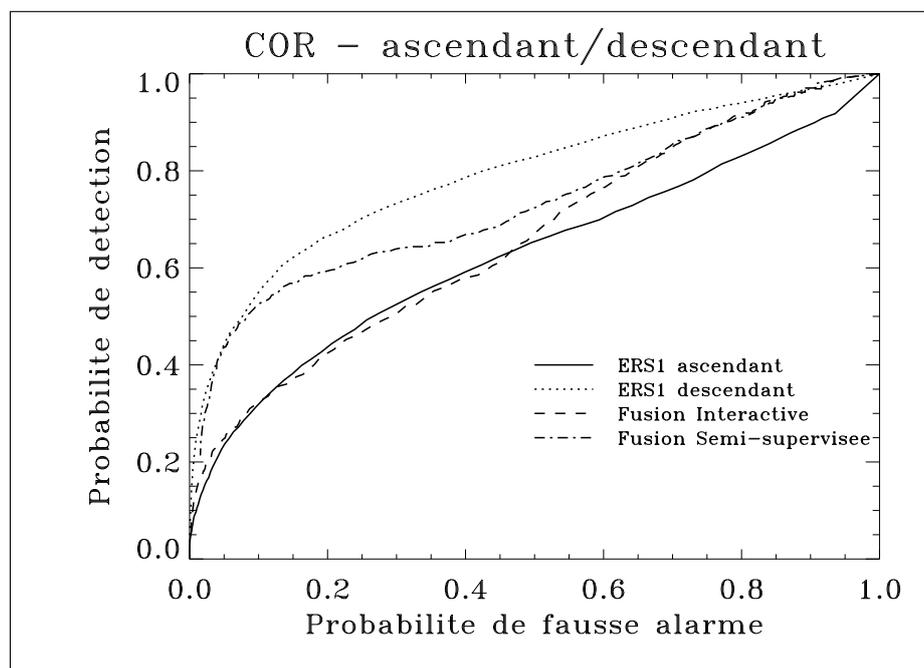


FIG. 6.20 – Evaluation des performances par courbes COR. Images recalées, géocodées et quantifiées.

leur détection comme structures spatiales peut changer en position ou en contraste, de telles structures spatiales instables sont considérées comme régions de changements (CT). Enfin, toutes les régions qui ne contiennent pas d'indices de changements temporels ou de structures spatiales stables sont considérées comme régions homogènes (RH). Les données retenues pour cette application proviennent de la série d'images de la région de Kourou présentée dans la section 3.2.

6.3.1 Attributs

Les attributs utilisés pour cette application sont deux attributs de contraste, le détecteur de contours multi-temporels (DCMT, sec. 4.2.4) et le détecteur de changements multi-temporels (DChMT, sec. 4.3.2), et un attribut de texture 3D, le log-cumulant d'ordre 2 ($\tilde{\kappa}_2$, sec. 4.4.3). Les caractéristiques des attributs sélectionnés offrent une complémentarité deux à deux, utilisable pour la détection simultanée des changements temporels et des structures spatiales stables. DCMT et $\tilde{\kappa}_2$ ont une même forte réponse pour les structures spatiales stables mais se comportent différemment pour les changements temporels. De même, DChMT et $\tilde{\kappa}_2$ ont une forte réponse pour des changements temporels mais l'attribut

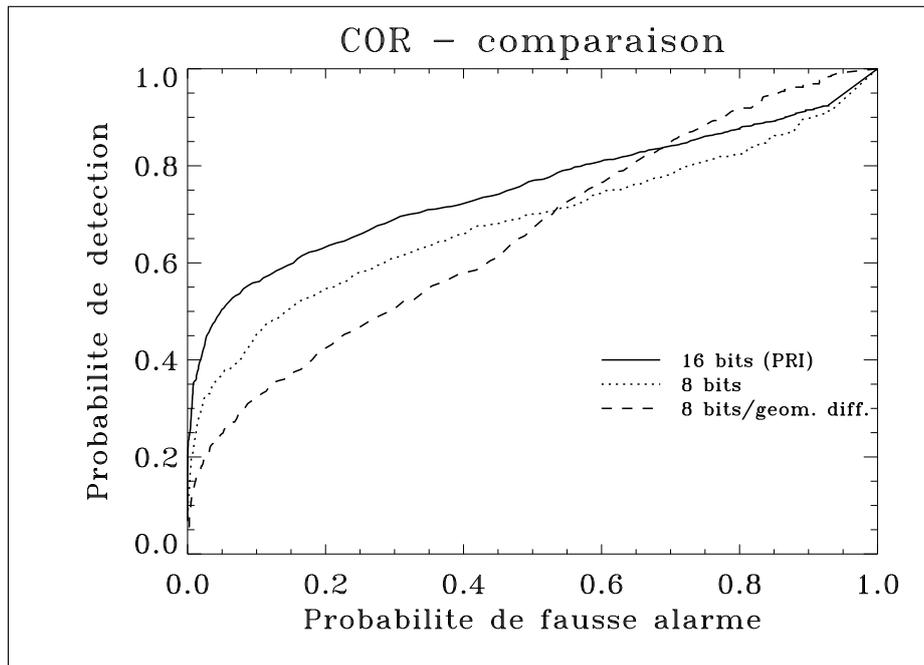


FIG. 6.21 – Comparaison des performances de l’opérateur de fusion en fonction du type d’images traitées.

DChMT reste de niveau faible en présence de structures spatiales stables.

6.3.2 Fusion

Le principe de la fusion des trois attributs est le même que celui décrit en 6.1.2.

6.3.3 Résultats

Le résultat du calcul des 3 attributs est illustré en figure 6.22. La classe CT est caractérisée par des valeurs élevées des attributs DChMT et $\tilde{\kappa}_2$, tandis que l’attribut DCMT a des valeurs faibles ; la classe SSS est caractérisée par des grandes valeurs pour l’attribut de texture $\tilde{\kappa}_2$ et l’attribut DCMT, tandis que l’attribut DChMT a des valeurs faibles.

Le résultat de la classification est présenté dans la figure 6.23(a). La classe CT couvre des régions comme l’océan, les rivières et les lacs où les changements sont dus aux variations de la surface de l’eau, ainsi que des régions inondables où les changements sont dus à la présence ou à l’absence d’eau. La côte, qui est instable temporellement dans cette région géographique, est aussi identifiée comme zone de changement. La classe SSS couvre les zones habitées et les bords des rivières. Le reste de l’image est classifié comme RH, spatialement

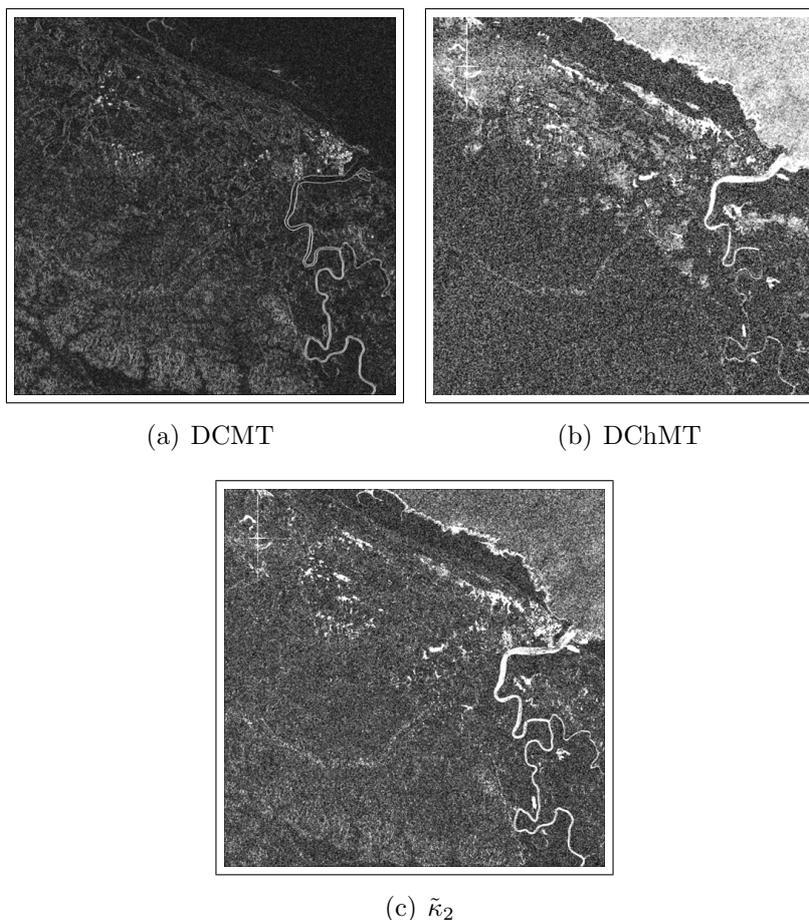


FIG. 6.22 – Images d’attribut : (a) DCMT ; (b) DChMT ; (c) le log-cumulant d’ordre 2 $\tilde{\kappa}_2$.

et temporellement. Il correspond aux zones de forêt tropicale.

Ces résultats sont comparés avec ceux obtenus par une méthode de classification non-supervisée (fig. 6.23(b)), la méthode des C-moyennes floues (FCM, sec. 5.2.1), et une méthode de classification supervisée (fig. 6.23(c)), la méthode Support Vector Machine (SVM, sec. 5.2.2), en utilisant en entrée les mêmes attributs que pour la fusion floue. Pour la classification supervisée, la connaissance *a priori* employée pour l’ajustement du système flou est utilisée pour générer un ensemble d’apprentissage pour les trois classes recherchées.

Une évaluation quantitative des performances est réalisée en calculant la matrice de confusion à partir des régions de référence (changements temporels, structures spatiales stables, régions homogènes) extraites de la vérité terrain (fig. B.14). Les matrices de confusion obtenues pour les trois méthodes de fusion/classification sont données dans les tableaux

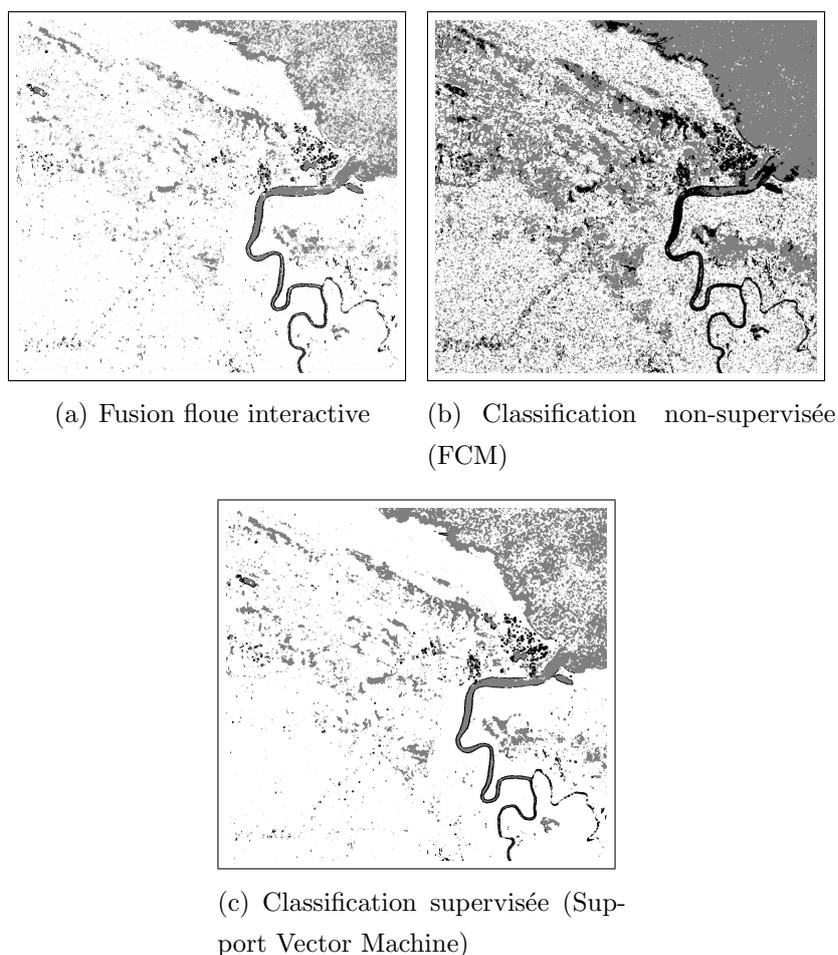


FIG. 6.23 – Comparaison des résultats de classification, noir : SSS, gris : CT, blanc : RH.

6.1, 6.2 et 6.3. Les indicateurs globaux associés à ces matrices (précision globale et coefficient kappa) montrent que la méthode de fusion floue permet d’obtenir une classification plus précise que la méthode non-supervisée grâce à l’introduction de la connaissance experte sur l’information apportée par les trois attributs. La méthode supervisée SVM réalise une classification plus précise que la méthode floue, à l’exception de la précision utilisateur pour la classe CT. L’explication tient peut être au fait que la classification floue, résultant des règles floues et des fonctions d’appartenance, est obtenue dans l’espace des attributs qui est interprétable par l’utilisateur mais ne permet pas toujours une séparation parfaite des classes recherchées. Inversement, la méthode SVM permet de trouver les hyperplans optimaux de séparation dans l’“espace des caractéristiques” où les données sont projetées par le noyau (cf. annexe E).

TAB. 6.1 – Matrice de confusion pour le résultat obtenu avec la méthode de fusion floue interactive : SSS - Structures Spatiales Stables ; CT - Changements Temporels ; RH - Régions Homogènes.

Classification \ Référence	SSS	CT	RH	Total	Précision Utilisateur
Structures Spatiales Stables	886	8	222	1116	79.4%
Changements Temporels	88	3451	9	3548	97.3%
Régions Homogènes	1194	217	19298	20709	93.2%
Total	2168	3676	19529	25373	
Précision Réalisateur	40.%	93.9%	98.8%		

Précision Totale : 93.2%
Kappa : 0.80

TAB. 6.2 – Matrice de confusion pour le résultat obtenu avec la méthode de classification non-supervisée (FCM).

Classification \ Référence	SSS	CT	RH	Total	Précision Utilisateur
Structures Spatiales Stables	1471	2214	636	4321	34.0%
Changements Temporels	404	1454	4146	6004	24.2%
Régions Homogènes	293	8	14747	15048	98.8%
Total	2168	3676	19529	25373	
Précision Réalisateur	67.8%	39.5%	75.5%		

Précision Totale : 69.6%
Kappa : 0.39

6.3.4 Conclusion

Les deux méthodes les plus performantes (SVM et fusion symbolique floue) correspondent à des contextes opérationnels différents. Les excellents résultats obtenus par le classifieur SVM reposent sur un ensemble d'apprentissage précis et ne permettent pas un ajustement interactif des classes recherchées (à moins de choisir un nouvel ensemble d'apprentissage). De plus, l'interprétation de l'“espace des caractéristiques” de dimension élevée, et même le choix du noyau le plus approprié ne sont pas faciles, en général, pour l'utilisateur.

La méthode de fusion floue repose sur la “connaissance experte”. Elle permet à l'uti-

TAB. 6.3 – Matrice de confusion pour le résultat obtenu avec la méthode de classification supervisée (SVM).

Classification \ Référence	SSS	CT	RH	Total	Précision Utilisateur
Structures Spatiales Stables	979	7	141	1127	86.9%
Changements Temporels	221	3606	7	3834	94.0%
Régions Homogènes	968	61	19383	20412	95.0%
Total	2168	3674	19531	25373	
Précision Réalisateur	45.2%	98.1%	99.2%		

Précision Totale : 94.5%
Kappa : 0.84

lisateur de contrôler la classification avec ses propres mots (la description linguistique des attributs) en ajustant progressivement leur interprétation numérique via les fonctions d'appartenance.

6.4 Bilan

Les exemples présentés dans ce chapitre mettent en évidence le gain en performances que l'on peut obtenir en combinant plusieurs attributs extraits d'une série d'images RSO multi-temporelles. L'aspect interactif de cette approche est bien adapté au contexte opérationnel de l'exploitation des images RSO dans les Sciences de la Terre.

Du point de vue du thématicien, l'intérêt de l'approche floue est de limiter la phase de réglage à l'analyse d'une très petite zone de l'image, puis de laisser le système de fusion produire des résultats sur des régions pouvant être très étendues (100 × 100 km pour des images RSO 8000 × 8000). L'interaction avec le système de fusion ne nécessite pas de connaissances particulières sur les mécanismes de fusion d'informations.

Chapitre 7

Conclusions et perspectives

Les travaux présentés dans cette thèse s’articulent autour de trois axes : deux axes méthodologiques, l’extraction et la fusion d’informations en imagerie RSO multi-temporelle et un axe plus thématique : l’application des méthodes proposées à la détection de changements et d’objets géographiques stables.

Les attributs développés dans l’axe “extraction d’informations” ont été regroupés au chapitre 4. Ils contribuent à enrichir la “bibliothèque” des paramètres dédiés à l’analyse des images radar aux résolutions actuelles des données satellitaires. Cette “bibliothèque”, fruit du travail de la communauté “imagerie radar” au cours des quinze dernières années, comporte de nombreux paramètres couplés à des techniques d’estimation adaptées aux spécificités des données RSO. Ces paramètres sont généralement dédiés aux images mono-temporelles. Ils permettent d’obtenir une information plus discriminante que la radiométrie initiale en vue de la détection de divers types de structures (cf. [MAÎTRE, 2001]–chap. 8). Les attributs que nous proposons s’appuient sur ces paramètres et les étendent au cas multi-temporel pour exploiter soit la redondance de l’information en vue d’améliorer la détection des structures stables, soit les modifications de la radiométrie pour détecter les changements survenus entre les acquisitions. Les performances des méthodes proposées et leur sensibilité au paramétrage ont été évaluées sur les données PRI des satellites ERS dont les archives importantes permettent aujourd’hui de disposer de séries multi-temporelles dans de nombreuses régions.

Les attributs proposés couvrent les principaux types de structures afin de pouvoir traiter des objets ponctuels (points brillants), linéaires simples (contours) ou doubles (route, rivière fine) et surfaciques (champs, forêts, etc.). Ces paramètres ont l’avantage d’être rela-

tivement génériques et peuvent être facilement mis en œuvre pour traiter différentes applications. La poursuite de cet axe pourrait conduire au développement de paramètres plus spécifiques basés sur une plus forte information de nature radiométrique, morphologique (2D) ou temporelle. La prise en compte par exemple des dimensions d’objets recherchés pour les structures fines ou de l’évolution de la radiométrie au cours du temps pour les forêts et les zones de cultures permettra, pour certaines applications, d’améliorer les performances initiales des attributs, au détriment de leur généralité.

Le second axe méthodologique consiste à fusionner les informations extraites sous forme d’attributs par une méthode adaptée au contexte de l’analyse des images RSO multi-temporelles. Une étape de fusion est nécessaire pour tirer parti de ces données dans chacune des deux directions explorées : pour la détection des structures stables, l’exploitation de la redondance de l’information présente dans plusieurs images conduit naturellement à la fusion de paramètres estimés dans chacune des images. Pour la détection de changements, les paramètres mesurés sont de type “différence” ou “variabilité” temporelle. Ces paramètres qui ont tendance à rehausser le niveau de bruit sont particulièrement sensibles au phénomène de chatoiement (speckle) qui entache les images radar. Dans les deux cas, la fusion de plusieurs paramètres et éventuellement d’attributs issus d’informations a priori permet d’améliorer la détection de structures difficilement détectables à l’aide d’un seul paramètre.

Le contexte de collaboration avec des “géophysiciens”, notamment au sein du laboratoire *Géomatériaux* de l’Institut Francilien de Géosciences, Université de Marne-la-Vallée, nous a conduit à développer une méthode de fusion interactive basée sur la connaissance qu’ont les experts des zones recherchées et du comportement des attributs. Le choix d’un système de fusion symbolique floue s’est effectué dans la continuité des travaux menés au LISTIC [VALET, 2001] dans le domaine de l’imagerie sismique. La méthode retenue consiste à effectuer une fusion symbolique interactive en s’appuyant sur la théorie des sous-ensembles flous pour relier l’univers numérique des attributs à l’univers symbolique des mots qui les décrivent et ceux correspondant aux classes thématiques recherchées. Présentée au chapitre 5, cette méthode a l’avantage d’être très générale (tous les attributs peuvent être décrits par un ensemble réduit de mots) et proche du raisonnement de l’expert grâce à la description du résultat attendu sous forme de règles floues. Une interface graphique dédiée à la fusion a été construite en IDL, langage du logiciel ENVI très répandu dans la communauté de la télédétection. Outre les fonctionnalités de réglage interactif des fonc-

tions d'appartenance, l'interface développée incorpore un ensemble de fonctionnalités qui la rendent facilement utilisable pour des opérateurs appartenant aux domaines d'application : d'une part la visualisation des données initiales, des attributs, des résultats de fusion floue (degrés d'appartenance) ou de classification après décision, d'autre part la sélection de zones de références utilisables à différents niveaux (aide à l'ajustement des règles en mode interactif par visualisation des points dans l'espace des attributs 2D ou 3D, apprentissage des règles en mode semi-supervisé, évaluation des résultats flous ou nets par courbes COR et matrices de confusion).

Cet axe a également donné lieu à la mise en œuvre de deux méthodes de classification, l'une automatique, les C-moyennes floues (*fuzzy C means*), l'autre supervisée, les SVM (*Support Vector Machine*). Ces deux classifieurs ont été appliqués pour fusionner les mêmes attributs afin de positionner la méthode proposée par rapport à des méthodes relativement "standards" et d'évaluer les performances des trois méthodes. Les résultats traduisent logiquement la supériorité d'une approche interactive ou supervisée. Les performances obtenues par SVM et par fusion interactive floue sont très proches, les différences étant du même ordre que celles des fluctuations liées à la sélection des régions d'apprentissage des SVM ou au réglage interactif des règles floues.

Deux aspects importants de l'axe fusion pourront donner lieu à une poursuite des travaux. D'une part, bien que la méthode de fusion floue ne limite pas le nombre d'attributs, l'ergonomie de l'interface de fusion interactive nous a conduit à nous limiter à trois attributs. L'extension à un plus grand nombre d'attributs nécessiterait un réglage dans des hypercubes dont la représentation et la perception par l'expert sont plus délicates. Un autre choix consisterait à ne pas fusionner les attributs en parallèle mais de façon séquentielle (en cascade). Cette stratégie est aujourd'hui possible pour un nombre restreint de classes recherchées en utilisant les sorties de fusions floues intermédiaires comme attributs des fusions suivantes. Néanmoins la mise en œuvre de cette stratégie repose fortement sur l'expert pour déterminer l'ordre des fusions et interpréter les résultats intermédiaires. Une autre approche utilisée au chapitre 4 dans le cas particulier de certains attributs de même nature consiste à effectuer une pré-fusion numérique de ces attributs. Afin d'explorer l'ensemble de ces pistes en effectuant des comparaisons quantitatives, il sera également nécessaire d'ajouter à l'évaluation de performance finale fournie par la matrice de confusion classique, des outils de suivi des performances intermédiaires tels qu'une mesure de l'information apportée par chaque attribut ou des matrices de confusion floues (avant décision). Ces travaux potentiels font partie des recherches en cours au LISTIC.

Enfin sur l'axe thématique, trois exemples d'application ont permis d'illustrer l'approche extraction-fusion sur des données multi-temporelles RSO acquises par les satellites ERS dans des régions tropicales humides. Dans ce type de régions à fort couvert nuageux, les capteurs RSO sont les seuls à pouvoir garantir une répétitivité des données compatible avec des applications de suivi des évolutions telles que l'érosion côtière, la déforestation ou la mise à jour de cartes. Les trois applications présentées au chapitre 6 permettent d'illustrer les méthodes proposées dans deux directions d'exploitation de l'imagerie multi-temporelle : la détection de changements et l'amélioration de la détection des structures stables. La première application illustre la difficulté de la détection de structures temporelles comme les changements dues à la déforestation de petites parcelles dans la région de Saint-Laurent du Maroni en Guyane Française. La seconde est consacrée à la détection de structures stables telles que des routes à l'est de Douala au Cameroun. Enfin la troisième application propose de combiner des attributs dédiés aux structures spatiales, aux structures temporelles et à la présence d'hétérogénéité 3D pour détecter simultanément ces deux types structures dans la région de Kourou en Guyane.

Les résultats obtenus permettent de tirer les conclusions suivantes :

- les données RSO ont un très fort potentiel pour la détection de changements tels que la déforestation, l'érosion côtière, les inondations, l'accroissement des zones urbaines etc. à condition de disposer de deux types d'outils : des paramètres de mesure de la variabilité temporelle adaptés à la rétrodiffusion radar et des outils de fusion d'attributs, une seule mesure conduisant rarement à des taux de classification automatique acceptables.
- pour certaines thématiques nécessitant l'extraction de réseaux fins (routes, voies ferrées, petits cours d'eau, etc.), la résolution décimétrique des données RSO satellitaires actuelles est encore un obstacle majeur à leur utilisation. L'exploitation de la redondance apportée par les données multi-temporelles permet, pour des images acquises sous le même angle de visée, d'améliorer légèrement les performances en détection automatique de structures stables, notamment grâce au recul des fausses alarmes sous réserve que les images soient le plus décorréélées possibles (à l'inverse des conditions interférométriques : bases suffisamment grandes, rétrodiffusion volumique, légère évolution temporelles, etc.).
- une détection simultanée des discontinuités spatio-temporelles permet une analyse globale de l'information présente dans les volumes formés par les images multi-temporelles. Cette approche permet notamment de discriminer ces deux types d'in-

formations auxquelles sont sensibles les détecteurs dédiés à l'une ou l'autre des structures. Les taux de classification de l'ordre de 95% obtenus soit par l'approche de fusion floue interactive proposée, soit par classification supervisée constituent un très bon résultat en imagerie radar multi-temporelle.

En conclusion, il nous semble que les freins qui subsistent dans la communauté de la télédétection vis-à-vis des données radar par rapport aux données optiques viennent principalement de la faible diffusion d'outils de traitements spécifiques autres que quelques filtres de speckle mono-temporels qui détériorent la résolution spatiale sans apporter l'information recherchée. Le développement et le transfert vers les utilisateurs finaux de "bibliothèques" d'attributs dédiés à l'extraction d'informations dans les séries d'images radar est une première étape nécessaire en vue d'une meilleure utilisation de ces données. Cette étape est en train d'être franchie, notamment au travers de collaboration entre laboratoires méthodologiques et thématiques. Mais contrairement à l'imagerie optique où des index de végétation ou des cartes de différences peuvent conduire à des résultats satisfaisants, l'imagerie radar nécessite également le transfert de méthodes de fusion d'informations permettant de combiner un ensemble de paramètres sélectionnées par les experts. Lorsqu'elle est réalisée, cette seconde étape utilise le plus souvent des classifieurs supervisés très performants tels que les réseaux de neurones ou les SVM. Cependant ces méthodes nécessitent de posséder ou de créer des ensembles d'apprentissage, et sont souvent perçues comme des boîtes noires avec lesquelles il est difficile d'interagir pour améliorer un résultat insatisfaisant. La méthode de fusion floue interactive proposée est une alternative à ces méthodes qui permet d'intégrer les connaissances expertes et de laisser l'utilisateur final piloter la fusion vers une solution satisfaisante.

Les perspectives d'utilisation des méthodes proposées sont liées aux évolutions actuelles de l'imagerie satellitaire. Les masses de données importantes acquises par les satellites précédents et actuellement opérationnels tels qu'Envisat constituent une archive colossale dont l'exploitation "multi-temporelle" est encore limitée à quelques applications. Les outils développés au cours de cette thèse seront diffusés dans le cadre d'un logiciel libre afin de contribuer à la mise à disposition d'outils de traitement facilitant l'exploitation des données RSO actuelles. Dans un futur proche une nouvelle génération de satellites sera lancée avec une amélioration sensible de la résolution spatiale, ouvrant la porte à de nouvelles applications. La démarche extraction-fusion devrait rester d'actualité, mais il est probable que les nouvelles caractéristiques des données RSO nécessitent de faire évoluer les deux étapes de

traitement. L'étape d'extraction d'informations conduira au développement de nouveaux attributs qui s'appuient sur les caractéristiques des données futures (utilisation de la bande X pour le système Cosmo-SkyMed du projet ORFEO, résolution métrique, possibilité de survols plus fréquents grâce à des constellations de micro-satellites, etc.). L'étape de fusion sera quand à elle de plus en plus primordiale pour exploiter la plus grande diversité des données et des attributs qui en résultent (généralisation de la multi-polarisation, de la multi-incidence, voire à plus long terme des systèmes multi-bandes).

Troisième partie

Annexes

Annexe A

Principes de l'imagerie RSO

Le radar à synthèse d'ouverture (RSO) est un système de télédétection, fondamentalement différent des systèmes optiques. C'est un capteur actif, c'est-à-dire un système qui fournit sa propre radiation, et n'est pas dépendant de la lumière du soleil, par conséquent permet le fonctionnement continu jour-nuit. De plus, les effets de la couverture nuageuse et les perturbations météorologiques qui affectent les systèmes optiques sont inexistantes pour les RSO. Sans rentrer dans les détails de la synthèse des images radar, nous décrivons dans cette annexe les principes de la formation de l'image RSO complexe et les conséquences géométriques (déformations) de l'échantillonnage en distance et les caractéristiques radiométriques des images détectées (amplitude ou intensité). Nous nous appuyons sur les présentations faites par Maître [[MAÎTRE, 2001](#)] et Trouvé [[TROUVÉ, 1996](#)].

A.1 Imagerie RSO

La technologie radar s'est développée pendant la deuxième guerre mondiale afin de détecter la présence d'une cible et d'en mesurer la distance et la vitesse. Le radar opère principalement dans le domaine des hyperfréquences à des longueurs d'onde λ de l'ordre du centimètre. La résolution angulaire d'une antenne de largeur L_a étant proportionnelle au rapport λ/L_a , la résolution spatiale à une distance R est proportionnelle à $R\lambda/L_a$. Aux longueurs d'onde centimétriques, même pour des tailles d'antenne importantes, la localisation spatiale dans le plan normal à l'onde électromagnétique est très mauvaise dès que la distance R devient importante.

Néanmoins, embarqué à bord d'un avion, le radar à ouverture réelle est rapidement employé pour observer des cibles fixes au sol. Il est alors utilisé en visée latérale, ce qui

permet d'exploiter sa résolution en distance dans la direction normale à la trajectoire. Ce système appelé SLAR (*Side Looking Airborne RADAR*) fournit les premières "images" radar. Mais leur résolution dans la direction parallèle à la trajectoire du porteur (appelée *azimutale*) reste très faible.

L'apparition dans les années 50 de la théorie de l'antenne à ouverture synthétique permet d'utiliser le déplacement du porteur pour synthétiser une antenne virtuelle de longueur très importante (fig. A.1). Ce système désigné par les initiales SAR (*Synthetic Aperture Radar*) ou RSO (Radar à Synthèse d'Ouverture) améliore considérablement la résolution dans la seconde direction de l'image. Elle devient indépendante de la distance R , avec pour limite théorique $L_a/2$ [CURLANDER and McDONOUGH, 1991].

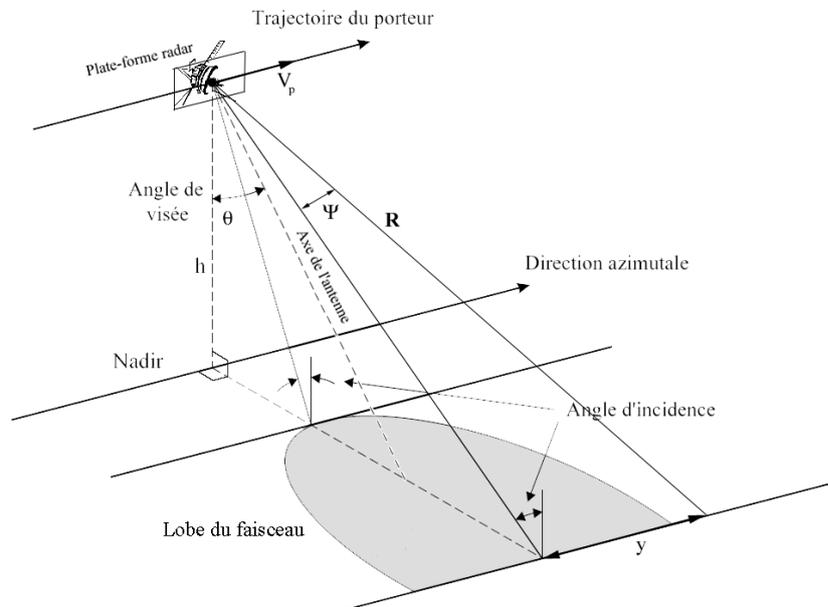


FIG. A.1 – Acquisition des images RSO.

L'imagerie RSO s'est depuis considérablement développée, aussi bien en aéroporté que sur des plates-formes spatiales telles que le satellite SEASAT, les missions de la navette spatiale (SIR-A, SIR-B, SIR-C) et les satellites ERS-1/ERS-2, Envisat, JERS-1, RADARSAT. Le capteur RSO équipe également des sondes d'exploration spatiale. Sa capacité à imager au travers du couvert nuageux a permis par exemple d'établir la première cartographie complète de la planète Venus lors de la mission Magellan (1990).

Pour une description complète des systèmes radar imageurs on peut se reporter à l'ouvrage de Curlander [CURLANDER and McDONOUGH, 1991].

A.2 Principes de formation de l'image RSO

Les capteurs optiques classiques de type SPOT fournissent des images directement interprétables car la transformation géométrique (projection) qui conduit à leur formation est proche de celle de la vision humaine. Les images RSO en revanche sont le résultat d'un traitement complexe du signal électromagnétique rétrodiffusé. Sans entrer dans le détail du traitement effectué par les processeurs RSO, il est nécessaire d'en rappeler le principe afin de connaître les spécificités géométriques et radiométriques de l'image.

Si nous considérons la réponse d'une cible supposée ponctuelle, l'écho reçu permet de déterminer sa distance au radar et son angle de vue Ψ par rapport à la direction de pointage de l'antenne (fig. A.1). Le retard temporel τ entre l'impulsion et l'écho permet de déterminer la distance radiale R :

$$R = \frac{\tau c}{2} \quad c : \text{vitesse de la lumière} \quad (\text{A.1})$$

Sur une cible fixe, l'écart Doppler f_d de l'onde réémise dû au mouvement du porteur (de vitesse V_p) permet d'obtenir l'angle de vue et donc la coordonnée y de la cible :

$$f_d = \frac{2V_p}{\lambda} \sin(\Psi) = \frac{2V_p}{\lambda R} y \quad (\text{A.2})$$

Le signal brut bidimensionnel (τ, Ψ) enregistré représente la réflectivité des cibles ayant pour coordonnées (R, y) .

Ce signal doit ensuite être traité selon chacune des deux directions pour obtenir une image haute résolution. Nous adopterons par la suite la convention suivante : les lignes de l'image correspondent à la direction d'échantillonnage en distance, les colonnes à la direction azimutale.

En distance la haute résolution est obtenue par des techniques de compression d'impulsion. Le signal est émis sur une bande de fréquence B_r , ce qui permet d'obtenir une résolution en distance radiale Res_r inversement proportionnelle à B_r :

$$Res_r = \frac{c}{2B_r} \quad (\text{A.3})$$

Les colonnes de l'image intermédiaire ainsi formée correspondent chacune à un intervalle de distance. Pour les images RSO fournies par ERS-1, la largeur de bande en distance est de 15,55 MHz, d'où une résolution de l'ordre de 10 mètres. Pour l'incidence moyenne $\theta = 23^\circ$, la résolution en distance au sol $Res_x = Res_r / \sin \theta$ est de l'ordre de 25 mètres. La fréquence d'échantillonnage du signal étant de 18,96 MHz, la taille des pixels en distance

radiale, notée r , est de 7,9 mètres¹, ce qui donne une taille de pixel au sol de l'ordre de 20 mètres.

En azimut cette image intermédiaire n'est pas focalisée. La réponse d'une cible ponctuelle est étalée sur plusieurs centaines de lignes et apparaît dans une même colonne après correction des effets de migration en distance. Elle est vue pendant un intervalle de temps compris entre $-T/2$ et $+T/2$, T se déduisant du diagramme de directivité de l'antenne. Son spectre en azimut s'étale autour de la fréquence dite "Doppler centrale".

Si l'on souhaite obtenir la meilleure résolution possible en azimut, on utilise un filtrage adapté portant sur l'ensemble de la réponse spectrale. C'est le cas des images complexes mono-vue (*Single Look Complex - SLC*) fournies par l'Agence Spatiale Européenne (ESA), utilisées en interférométrie. Elles ont une résolution en azimut de l'ordre de 6 mètres pour une taille de pixel de 4,2 mètres.

Les images ainsi formées sont fortement entachées par le phénomène de speckle détaillé à la section A.3.2. L'intensité présente un aspect granuleux que l'on souhaite généralement réduire car il rend l'interprétation des images difficile. Pour cela on choisit de perdre en résolution azimutale au profit d'une meilleure radiométrie, en appliquant lors de la formation de l'image une technique de moyennage M -vues propre à l'imagerie RSO.

Le spectre azimutal est séparé en M parties, dont les fréquences correspondent à M vues différentes des cibles le long de la trajectoire. On forme alors M images de moins bonne résolution azimutale car acquises par des antennes synthétiques plus courtes. En revanche, ces antennes étant distinctes, les M images peuvent être considérées comme statistiquement indépendantes. Leur moyenne permet de créer une image dite M -vues où le speckle se trouve réduit d'un facteur \sqrt{M} . On pourrait confondre cette technique avec un moyennage spatial de M lignes d'une image mono-vue. Cependant un tel moyennage ne garantit pas l'indépendance statistique des pixels moyennés en raison du recouvrement entre les cellules de résolutions (zone du sol correspondant à un pixel). En pratique, les 2 résultats sont cependant assez proches.

Ce traitement classique en imagerie RSO s'avère souvent indispensable pour obtenir des images dont la radiométrie soit exploitable. Les images sur lesquelles nous avons travaillé au cours de cette thèse sont de type "PRI" (*PRecision Image*). Ce produit fourni par l'ESA à partir des données ERS-1/2 est une image d'amplitude 3-vues. Elle est également rééchantillonnée en distance pour obtenir un pixel carré de 12,5 mètres au sol.

¹ Le pas d'échantillonnage est en réalité le double de la distance indiquée car il correspond au trajet aller-retour. Par simplification, sauf nécessité contraire, nous raisonnerons toujours en distance simple.

A.2.1 Déformations

Le processus de formation des images RSO induit une géométrie d'observation des scènes très différente des projections auxquelles nous sommes habitués. Comme nous l'avons vu précédemment il faut distinguer les deux directions de l'image :

- dans la direction azimutale la localisation d'un pixel est comparable à une projection de type ortho-image,
- dans la direction radiale l'échantillonnage en distance introduit des déformations géométriques d'autant plus importantes que le terrain présente de fortes dénivellations.

Un point d'altitude élevée sera imagé plus près du début de ligne (nadir) que s'il était à une altitude basse. En particulier, les montagnes et les terrains en pente introduisent des déformations significatives. Les trois déformations principales produites sont : la *compression en avant* (foreshortening), le *repliement* (layover) et l'*ombrage* (shadowing). La distance entre l'objet imagé et la plate-forme sur laquelle est situé le capteur RSO est déterminée seulement par le délai du retour du signal émis. En ramenant différents points au sol sur un axe de distance (fig. A.2–A.4) la rétrodiffusion du point a est perçue au point a' .

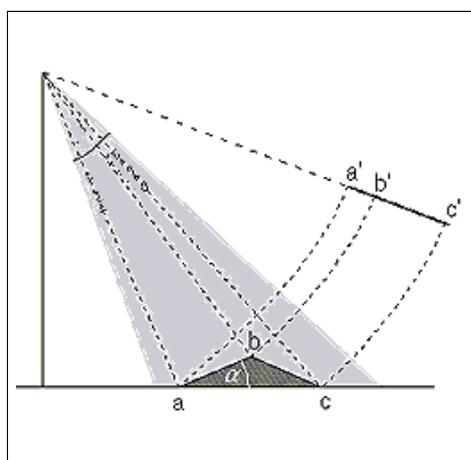


FIG. A.2 – La compression en avant.

La *compression en avant* est causée quand le faisceau RSO frappe une montagne en pente douce orienté vers le radar (fig. A.2). Nous observons comment la distance $a'b'$ dans l'image RSO est beaucoup plus petite par rapport à la distance au sol réelle ab . Par conséquent, la superficie de la partie antérieure de la montagne dans une image RSO sera plus petite que la superficie réelle.

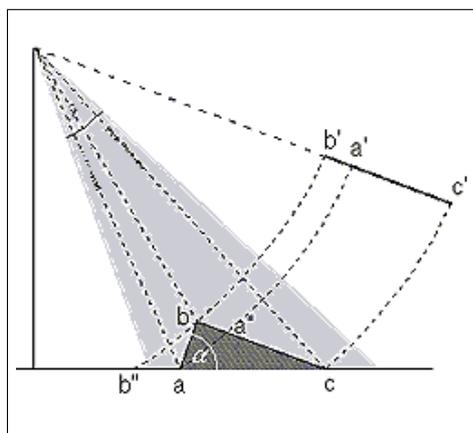


FIG. A.3 – Le repliement.

Le *repliement* est provoqué par des versants de montagne très abrupts comme dans la figure A.3. Nous observons que la rétrodiffusion du point b (b') est reçue avant la rétrodiffusion du point a . Ceci cause des structures visibles sur l'image : la pente antérieure de la montagne semble être “couchées” (superposées) sur la face postérieure de la montagne.

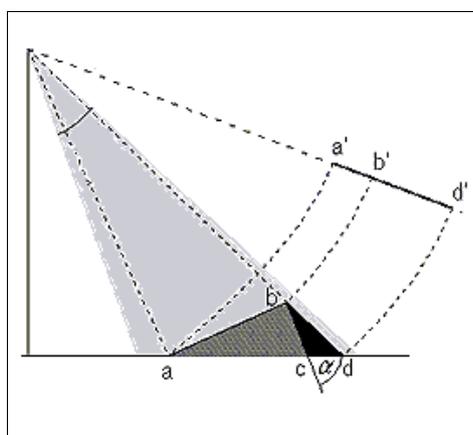


FIG. A.4 – L'ombrage.

La troisième déformation géométrique, l'ombrage, est provoquée par une pente abrupte de la montagne, comme dans la figure A.4. Nous observons l'absence de rétrodiffusion entre les points b et d due à un effet d'ombrage du sommet de la montagne.

L'angle d'incidence du faisceau radar affecte également le coefficient de rétrodiffusion (fig. A.5). Plus l'angle de la pente illuminée par le RSO se rapproche de la perpendiculaire au faisceau, plus le rayonnement renvoyé vers le capteur est important. Cet effet est à la base de la technique d'évaluation du relief à partir de l'intensité d'une image RSO sur des

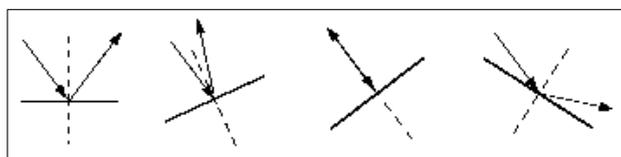


FIG. A.5 – Angles d'incidence.

zones homogènes [PAQUERAULT, 1998].

A.3 Propriétés du signal RSO

Nous présentons ensuite les caractéristiques du signal RSO en nous situant au niveau d'un pixel. Formé à partir de la réponse du sol à une onde cohérente, ce signal complexe est sujet au phénomène du *speckle* (encore appelé *chatoiement*) dont nous rappelons les propriétés. L'image RSO peut être analysée sous la forme d'une image de phase et d'une image soit d'amplitude soit d'intensité selon que l'on détecte respectivement le module ou le carré du module.

A.3.1 Intensité

Les images d'intensité représentent la réponse du terrain à l'onde hyperfréquence émise par le radar, aux atténuations de transmission près. La radiométrie du pixel est fonction de l'interaction onde-matière sur la surface imagée correspondante. Elle dépend de deux ensembles de paramètres :

- les paramètres propres au radar (longueur d'onde - bande C, L, X ...-, polarisation, angle d'incidence, etc.),
- les paramètres liés à la nature du sol (réflectance, humidité, rugosité de la surface par rapport à la longueur d'onde, inclinaison du sol, etc.).

Les images d'intensité ont généralement un aspect très bruité, ce qui rend leur exploitation directe difficile. On distingue principalement deux types de bruits :

- un bruit thermique lié au système radar, que l'on peut considérer comme additif,
- le phénomène de *speckle* dû aux superpositions constructives ou destructives des réflexions élémentaires qui contribuent à la réponse en un pixel. Le *speckle* confère à l'image un aspect granulaire commun aux systèmes d'imagerie utilisant une source d'éclairement cohérente (laser, radar, etc.).

A.3.2 Propriétés du speckle

La modélisation de la formation du speckle la plus utilisée reprend le formalisme de Goodman [GOODMAN, 1976]. La réponse d'une cellule de résolution (zone du sol dont la rétrodiffusion contribue au signal mesuré en un pixel) est la somme de N réponses de cibles ponctuelles aléatoirement réparties dans la cellule. En notant $s_i = \rho_i e^{j\phi_i}$ la réponse de la cible i , la réponse de la cellule est :

$$S = \Re(s) + j\Im(s) = \sum_{i=1}^N \rho_i e^{j\phi_i} \quad (j^2 = -1) \quad (\text{A.4})$$

\Re et \Im désignent ici les parties réelles et imaginaires des données SLC, traditionnellement notées I et Q (en phase et en quadrature).

Sous les hypothèses suivantes :

- ρ_i et ϕ_i sont des variables aléatoires indépendantes,
- les phases ϕ_i sont indépendantes entre elles et suivent une loi uniforme sur $[0, 2\pi]$
- le nombre N est assez grand ($N \gg 5$),

le théorème central limite permet de conclure que les données complexes $S : (\Re, \Im)$ sont des vecteurs centrés gaussiens complexes circulaires, de variance σ^2 proportionnelle au coefficient de rétrodiffusion σ_0 [LEBERL, 1990].

Ce modèle est celui d'un speckle entièrement développé, où l'on considère qu'il n'y a aucun écho fort prépondérant dans la cellule de résolution. C'est le cas des surfaces homogènes dites *rugueuses*. Une surface est considérée rugueuse par rapport à la longueur d'onde λ et l'angle d'incidence θ lorsque l'écart type de son élévation σ_{el} vérifie :

$$\sigma_{el} \gg \frac{\lambda}{8 \cos \theta} \quad (\text{A.5})$$

Pour les données détectées, l'amplitude $A = |S|$ suit alors une distribution de Rayleigh, loi à un paramètre $R = 2\sigma^2$ qui correspond à la réflectivité radar du pixel (surface équivalente radar - SER - si les données sont calibrées) :

$$P_A(x) = \frac{2x}{R} \exp\left(-\frac{x^2}{R}\right), \quad x \geq 0$$

de moyenne $\mu_A = \sqrt{\pi R}/2$ et d'écart type proportionnel à la moyenne $\frac{\sigma_A}{\mu_A} = \sqrt{\frac{4}{\pi}} - 1$.

L'intensité $I = |S|^2$ suit une loi exponentielle de densité de probabilité (d.d.p.) :

$$P_I(x) = \frac{1}{R} \exp\left(-\frac{x}{R}\right), \quad x \geq 0 \quad (\text{A.6})$$

dont les moments d'ordre 1 et 2 sont égaux : $\mu_I = \sigma_I = R$.

Lorsque les images sont issues d'un moyennage I_M d'intensité M -vues, la d.d.p. de l'intensité devient une loi Gamma :

$$P_{I_M}(x) = \frac{M^M x^{M-1}}{R^M \Gamma(M)} \exp\left(-\frac{Mx}{R}\right), \quad x \geq 0 \quad (\text{A.7})$$

où $\Gamma(M)$ désigne la fonction Gamma; M étant entier on a $\Gamma(M) = (M-1)!$.

Le rapport σ_{I_M}/μ_{I_M} qui vaut 1 pour les images mono-vues et $1/\sqrt{M}$ pour les images M -vues est appelé coefficient de variation (cv). Ce paramètre peut être estimé directement sur l'image et fournit ainsi une mesure locale de l'importance du speckle.

La distribution d'amplitude $A_M = \sqrt{I_M}$ suit quant à elle une loi Gamma généralisée :

$$P_{A_M}(x) = \frac{2M^M x^{2M-1}}{R^M \Gamma(M)} \exp\left(-\frac{Mx^2}{R}\right)$$

dont moyenne vaut : $\mu_{A_M} = \sqrt{\frac{\pi R}{4}}$. L'écart type est également proportionnel à la moyenne :

$$\frac{\sigma_{A_M}}{\mu_{A_M}} = \sqrt{\frac{M\Gamma^2(M)}{\Gamma^2(M+\frac{1}{2})} - 1}.$$

Cette proportionnalité entre la moyenne et l'écart type de l'amplitude ou de l'intensité conduit à décrire le speckle comme un bruit multiplicatif : les fluctuations sont d'autant plus importantes que la radiométrie est forte. Souvent considéré comme un bruit nuisible à l'exploitation des images RSO, le speckle peut au contraire être utile dans certaines approches pour caractériser des zones de l'image. Ses paramètres (cv, corrélation, etc.) servent alors d'attributs dans des processus de segmentation en régions, de détection ou de classification [[KELLY et al., 1988](#)].

D'autres travaux centrés sur l'étude de la radiométrie RSO présentent des lois différentes prenant en compte la non-homogénéité du sol. On peut citer notamment la loi K qui incorpore une modélisation de la texture du sol. Pour une présentation détaillée des modèles statistiques développées en imagerie RSO, on se reportera aux thèses de Laur [[LAUR, 1989](#)] pour le milieu terrestre et de Delignon sur les applications océanographiques [[DELIGNON, 1993](#)].

Annexe B

Illustration des images RSO multi-temporelles et des données complémentaires

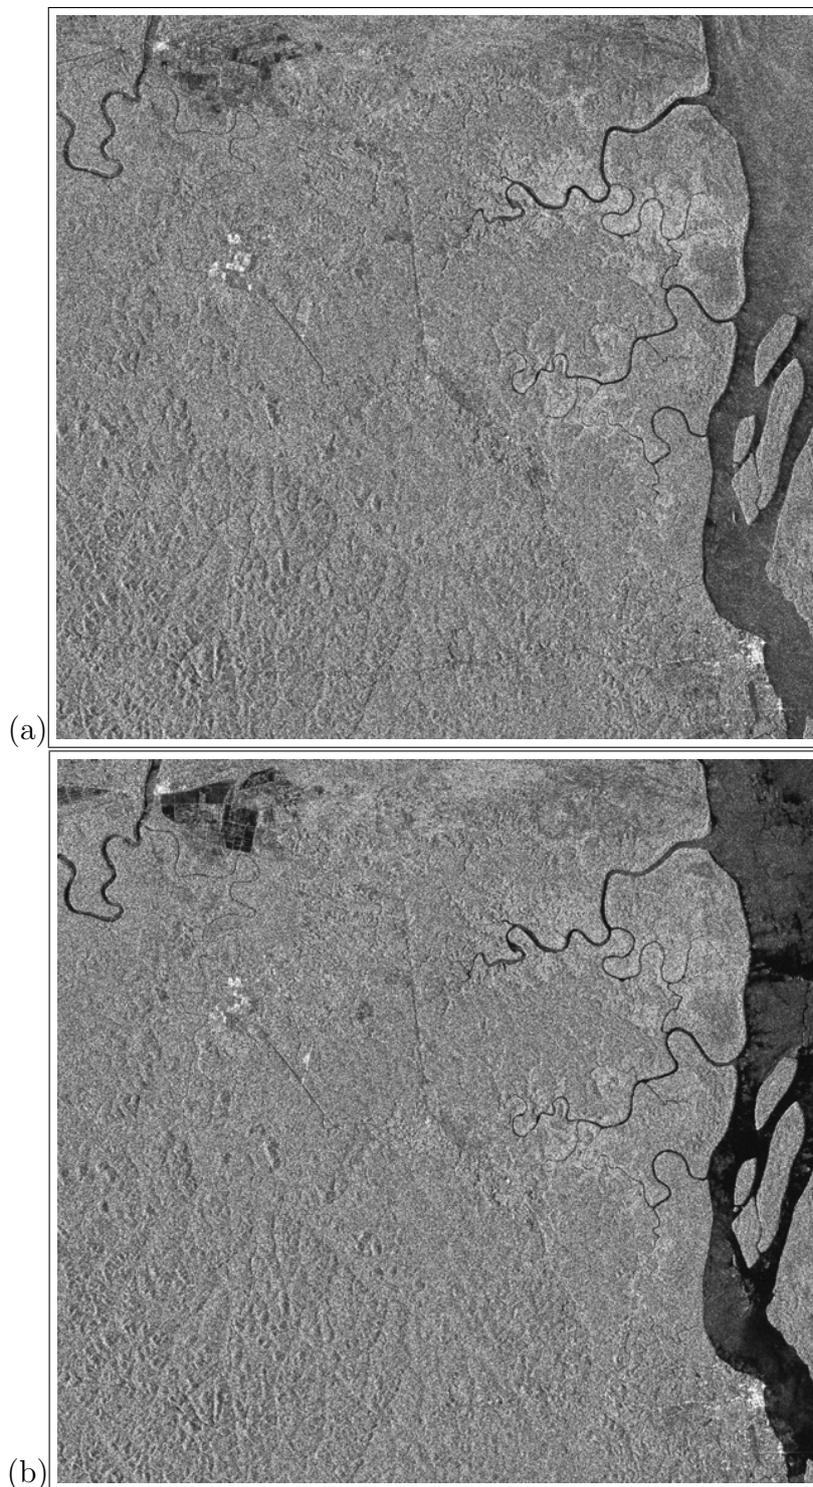


FIG. B.2 – Données multi-temporelles ERS-1 et ERS-2 sur la Guyane française, images 2300×2400 : (a) 6 mai 1992 ; (b) 10 juin 1992.

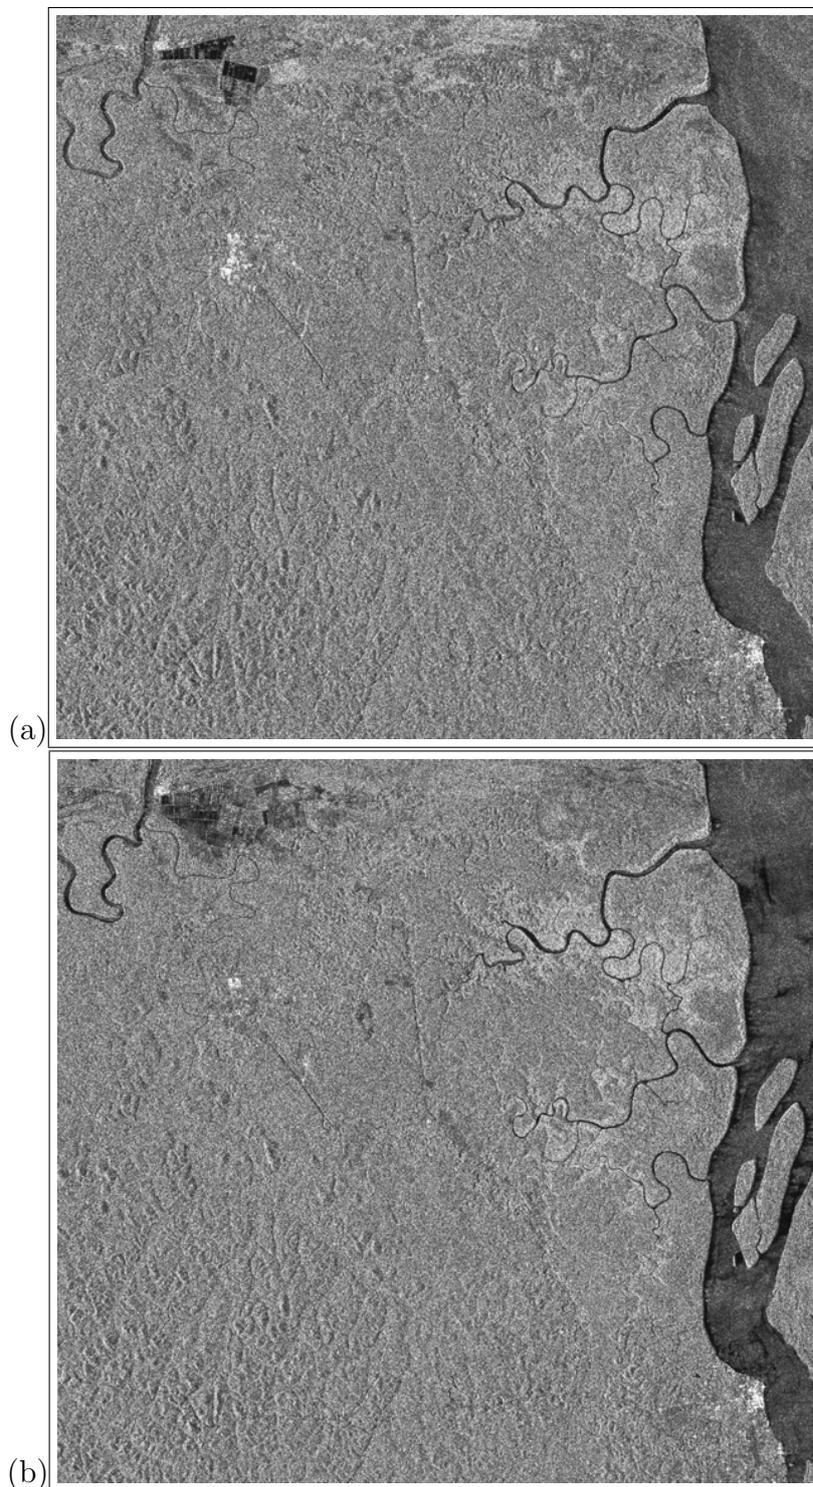


FIG. B.3 – Données multi-temporelles ERS-1 et ERS-2 sur la Guyane française, images 2300×2400 (cont.) : (a) 12 décembre 1992 ; (b) 26 mai 1993.

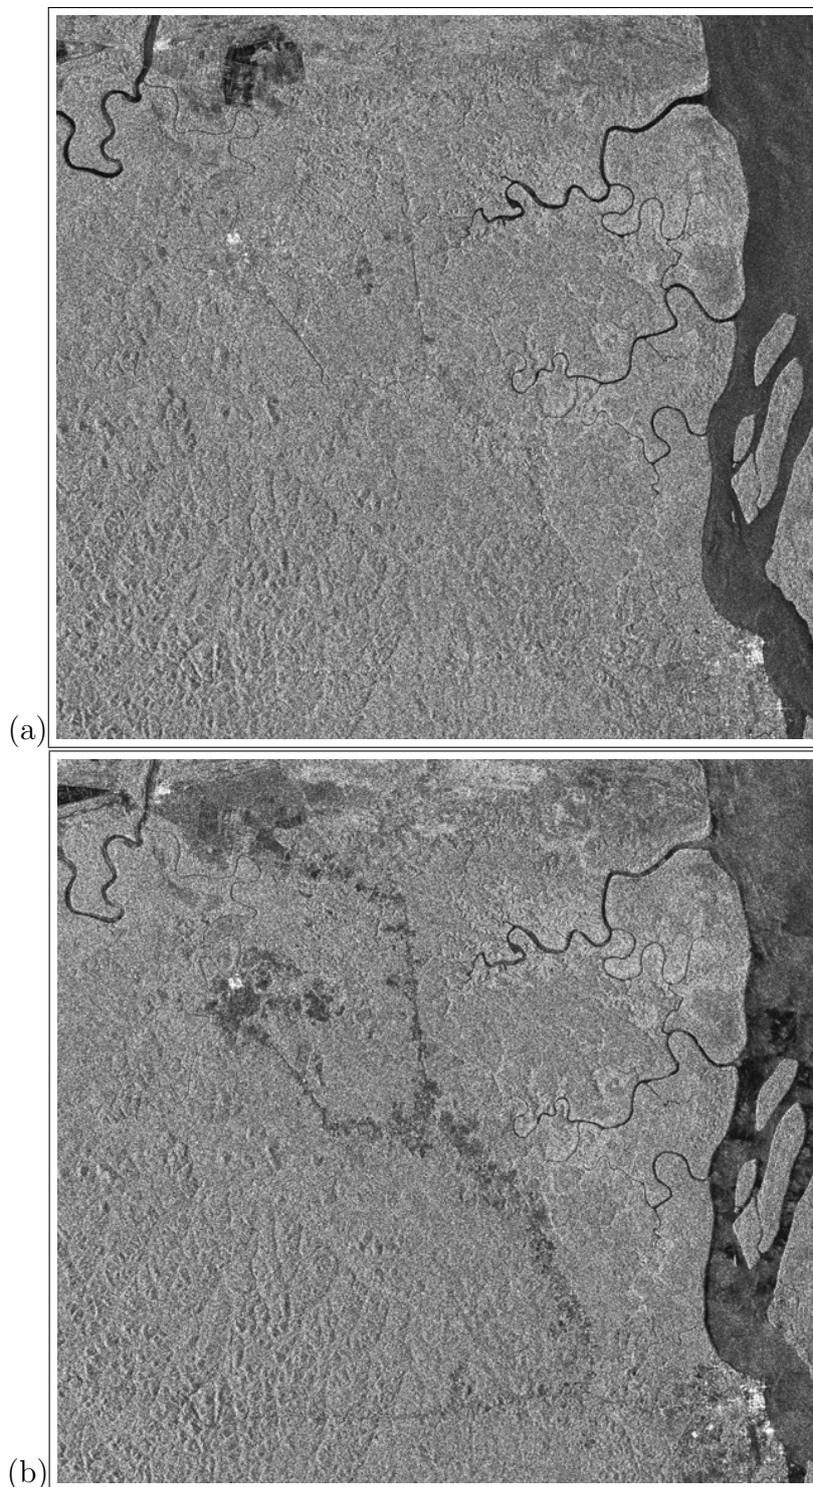


FIG. B.4 – Données multi-temporelles ERS-1 et ERS-2 sur la Guyane française, images 2300×2400 (cont.) : (a) 30 juin 1993 ; (b) 15 novembre 1997.

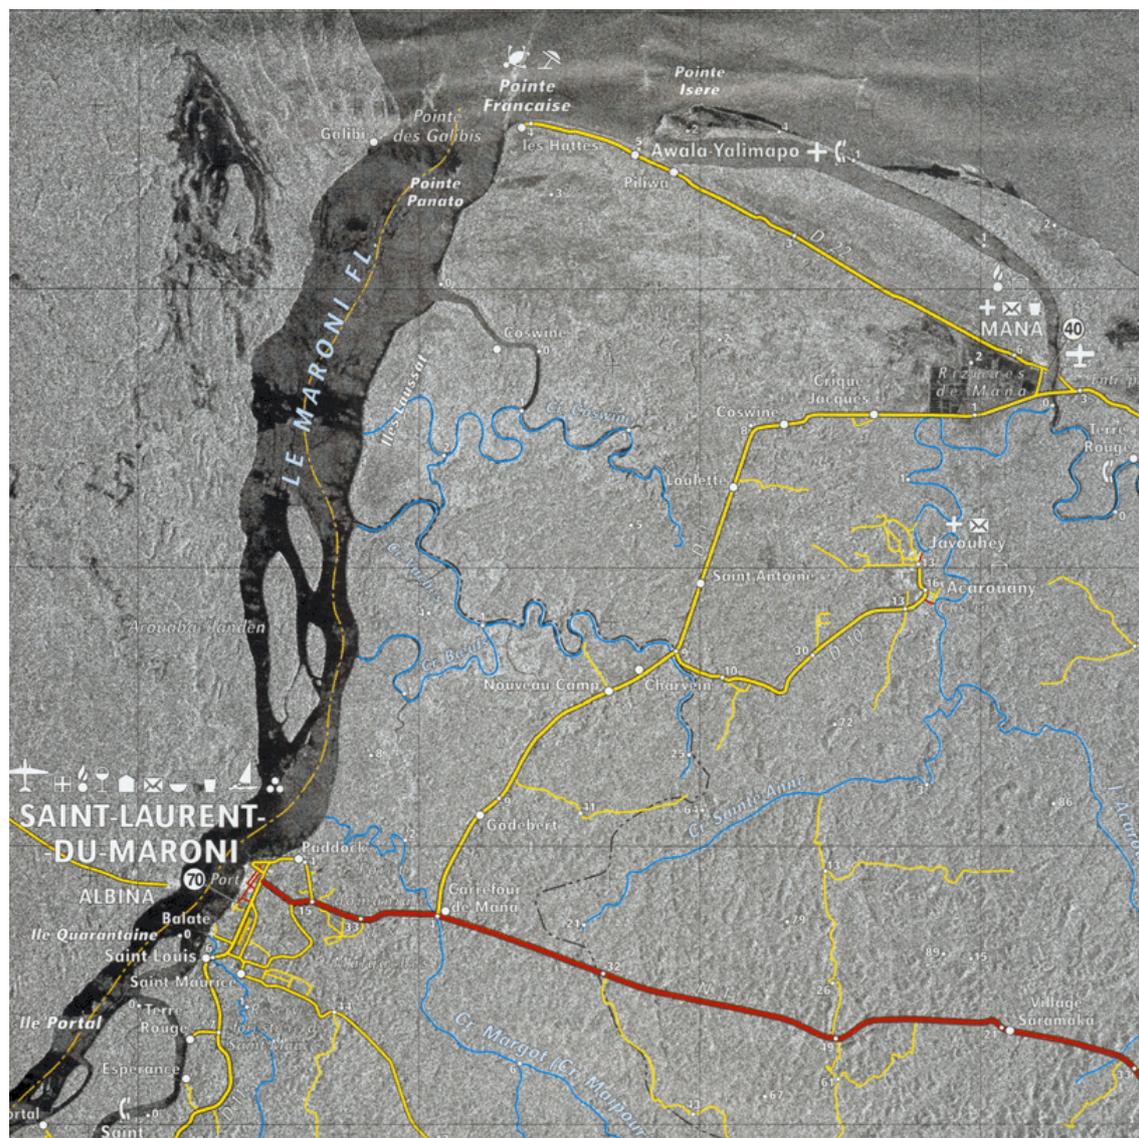


FIG. B.5 – Carte de la région de Saint-Laurent du Maroni, avec le réseau de routier et les données RSO en fond de carte, ©UMLV.

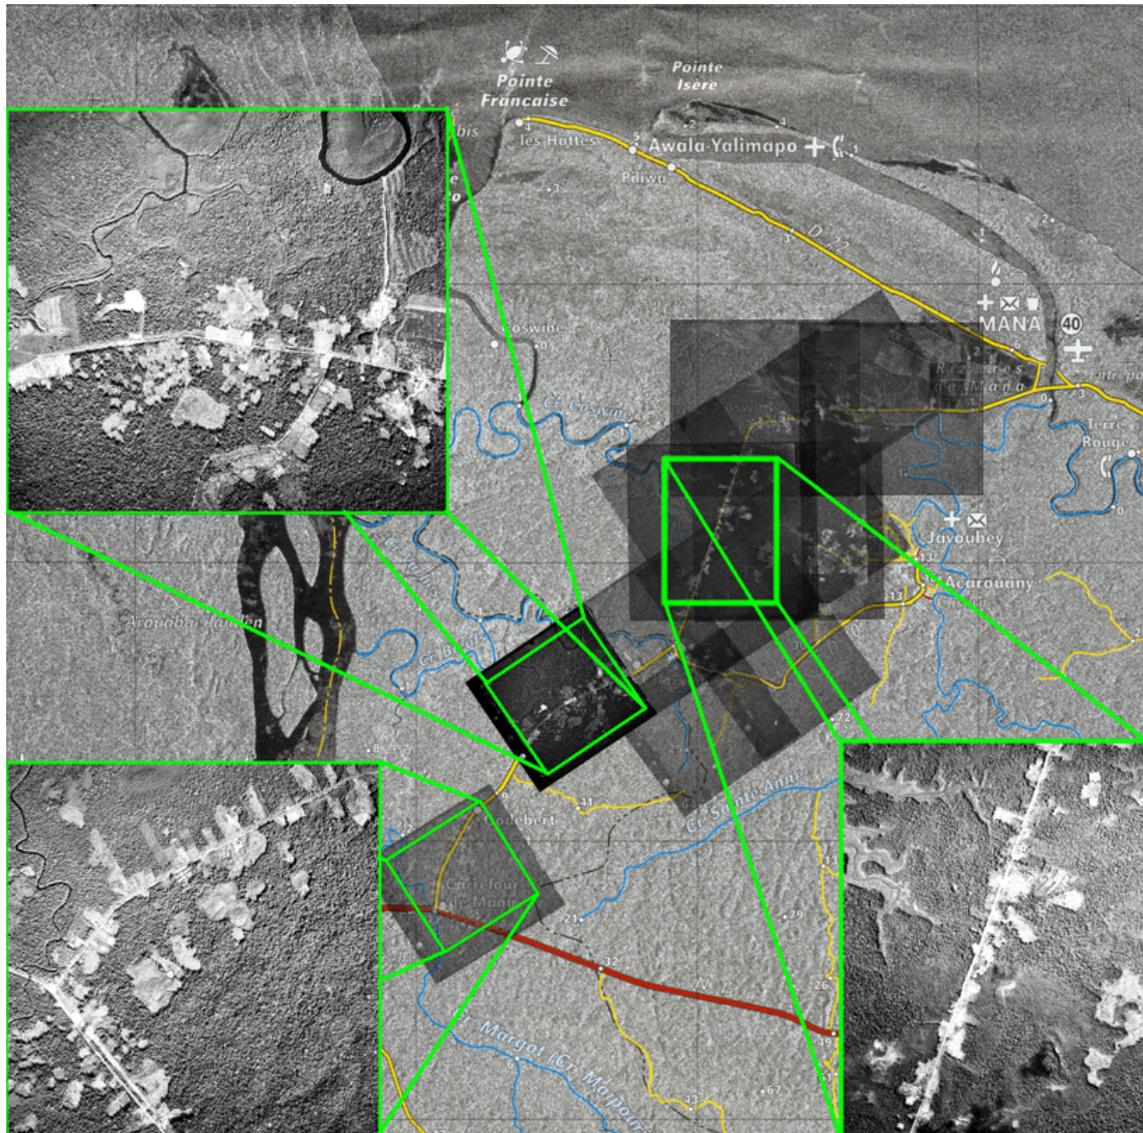


FIG. B.6 – Incrustation des photographies aériennes de 1991 et 1999 sur la carte précédente (fig. B.5).



FIG. B.7 – Photographie aérienne (numérisée) des abattis Guyane française, 1999.

B.2 Région de Kourou

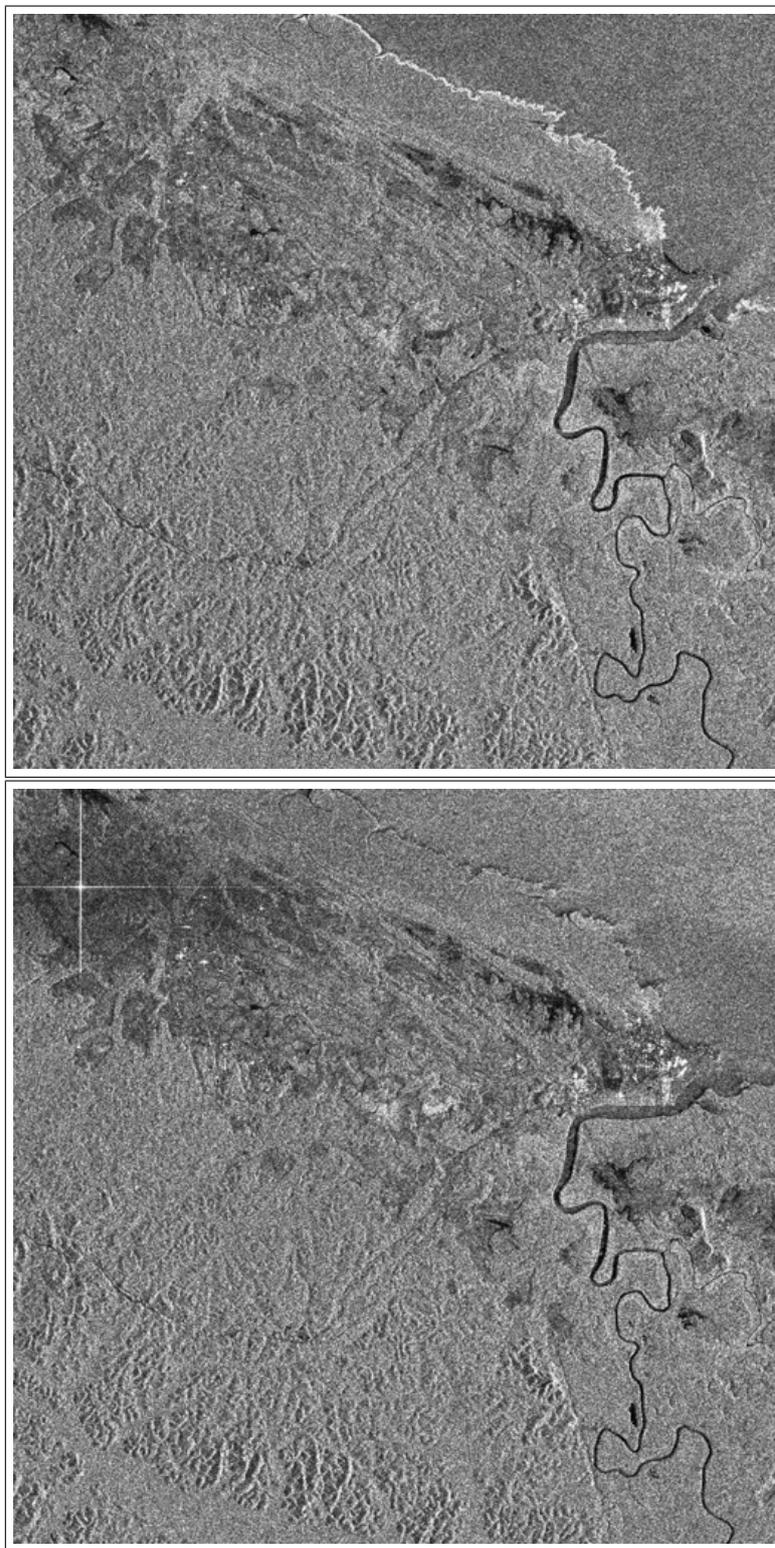


FIG. B.8 – Données multi-temporelles de la zone de Kourou, Guyane française.

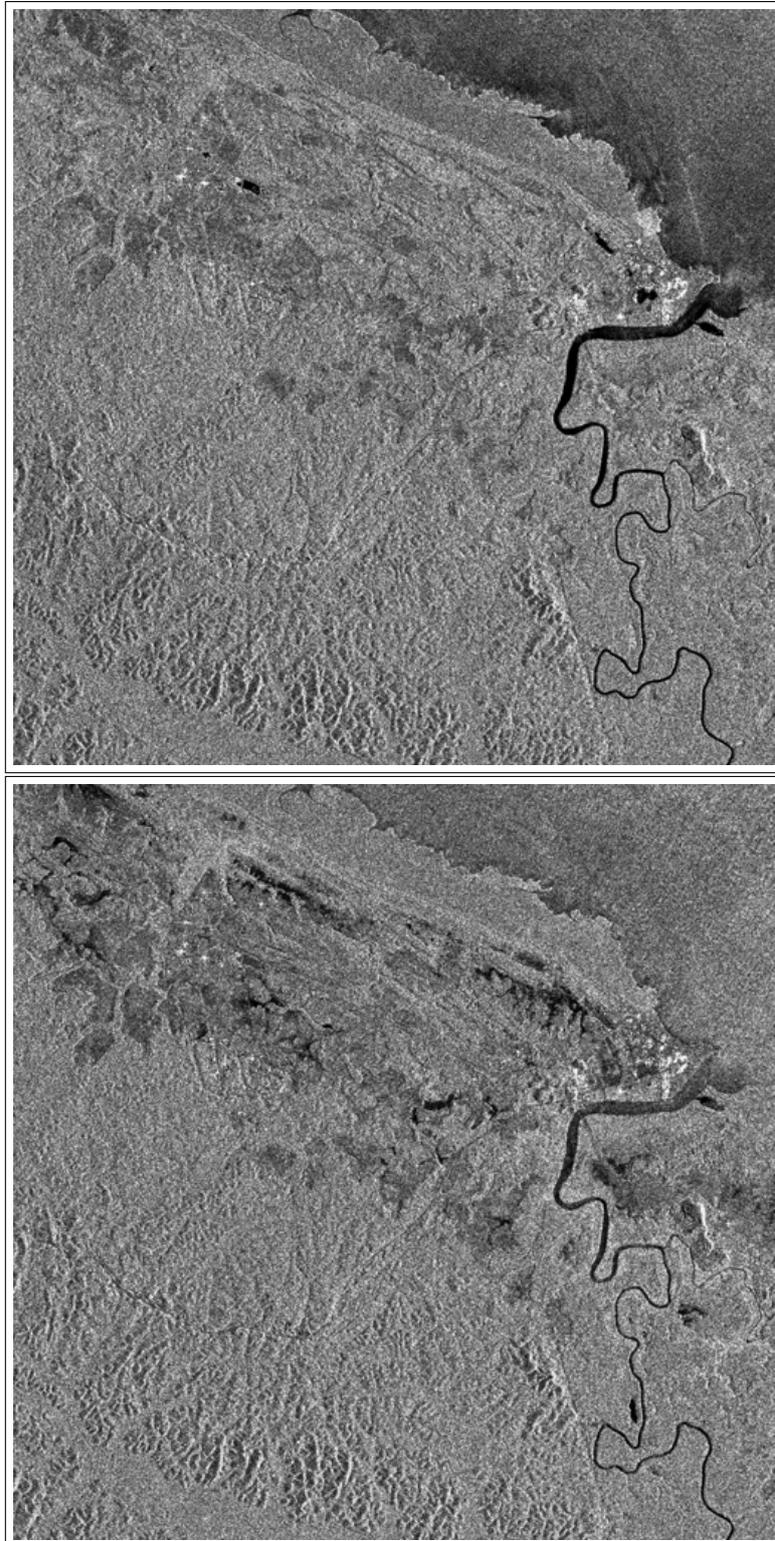


FIG. B.9 – Données multi-temporelles de la zone de Kourou, Guyane française (cont.).

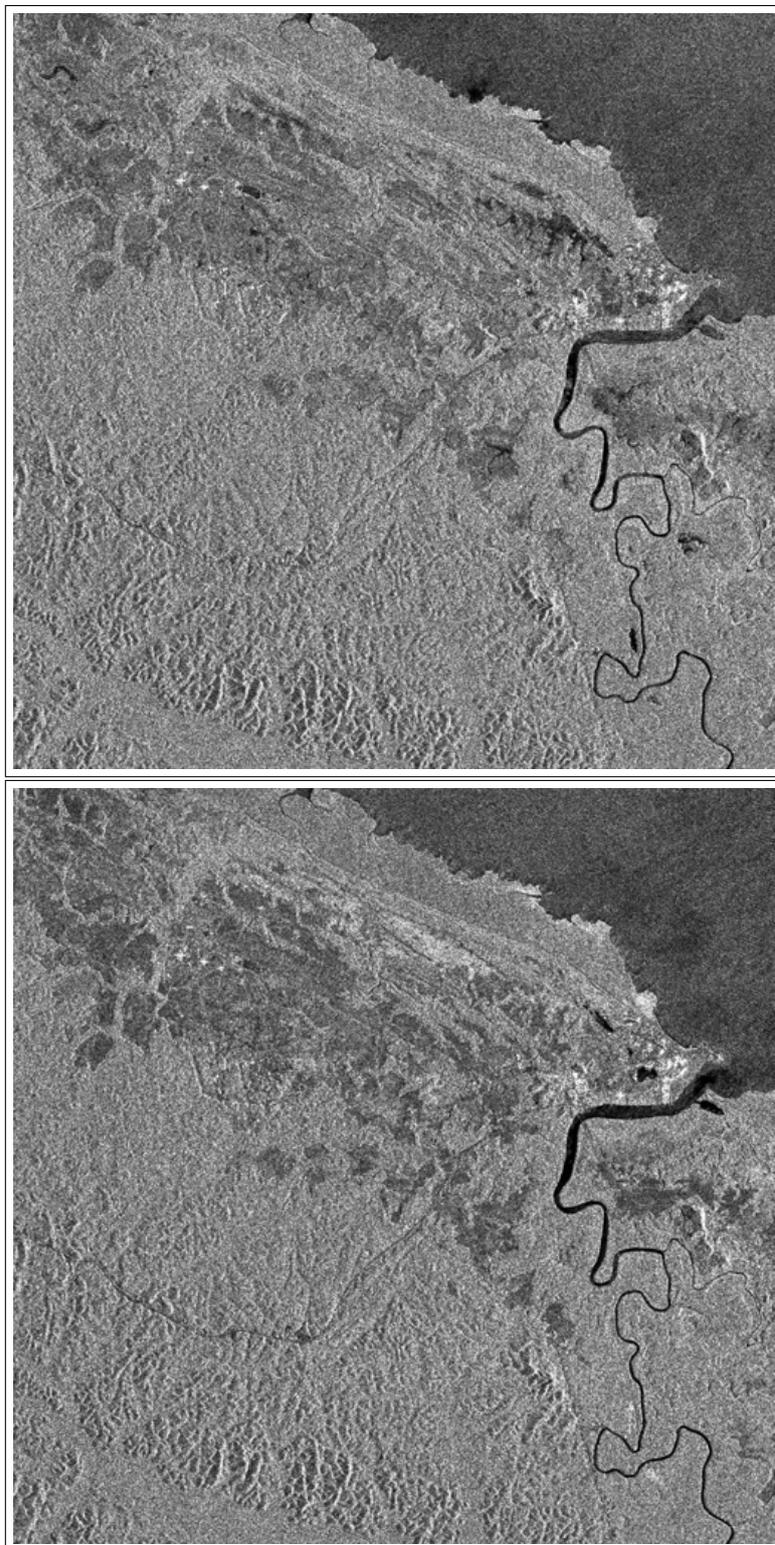


FIG. B.10 – Données multi-temporelles de la zone de Kourou, Guyane française (cont.).

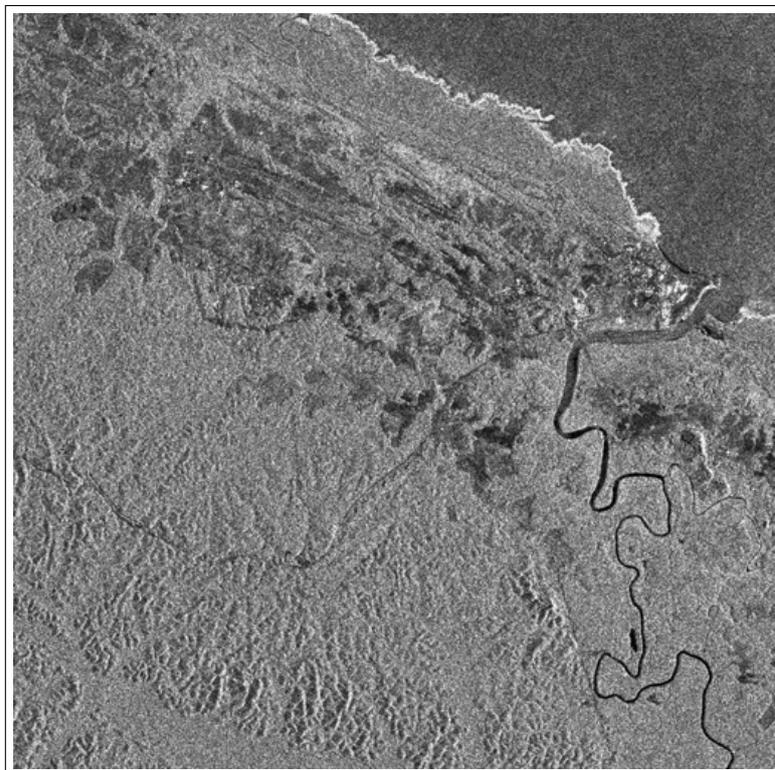


FIG. B.11 – Données multi-temporelles de la zone de Kourou, Guyane française (cont.).

LÉGENDE

Route routière	permanente
Route de praticabilité	saisonnière
Rue	
Piste forestière	
Piste piéton importante - Sentier	
Ligne électrique	
Zone bâtie - Constructions légères	
Mairie - Ecole	
P.T.T. - Gendarmerie	
Eglise - Temple - Cimetière	
Hôpital - Dispensaire	
Hôtel, Motel - Banque	
Location de véhicule automobile - Poste de carburant	
Stade - Carrère	
Gastronomie - Alcoolisme	
Cours d'eau - Surt	
Digra - Appontement	
Phare - Feu - Ecluse	
Voie - Pêche - Baïgnade - Piscine	
Site de ponte - Vestiges historiques - Point de vue	
Périètre du Centre Spatial Guyanais	

CAYENNE	
Chef-lieu de Département	
Limite et chef-lieu de Canton	
Limite et chef-lieu de Commune	
Village, quartier	
Habitations	
Altitude - Point géodésique	
maîtrise (tous les 200 m)	
normale (tous les 40 m)	
intercalaire (courbe 20 m)	
Digue - Canal	
Marais - Terrain humide	
Terrain inondable - Mangrove (limite de 1984)	
Forêt, Espaces verts (en ville) - Forêt dégradée	
Savane, Prairie - Plantation	
Pont - Limite de charge	
Distances kilométriques - Classification des routes	

Km	0	1	2	3	4	5	6	7	Km
----	---	---	---	---	---	---	---	---	----

Échelle 1:100 000

INSTITUT GEOGRAPHIQUE NATIONAL
 SERVICE DES VENTES ET ÉDITIONS
 136 bis, rue de Grenelle - 75700 Paris.
 Mise à jour par exploitation de la couverture photographique aérienne de 1987
 et des renseignements obtenus auprès de l'administration départementale.
 2ème édition : 1987.
 ©IGN, Paris 1987.

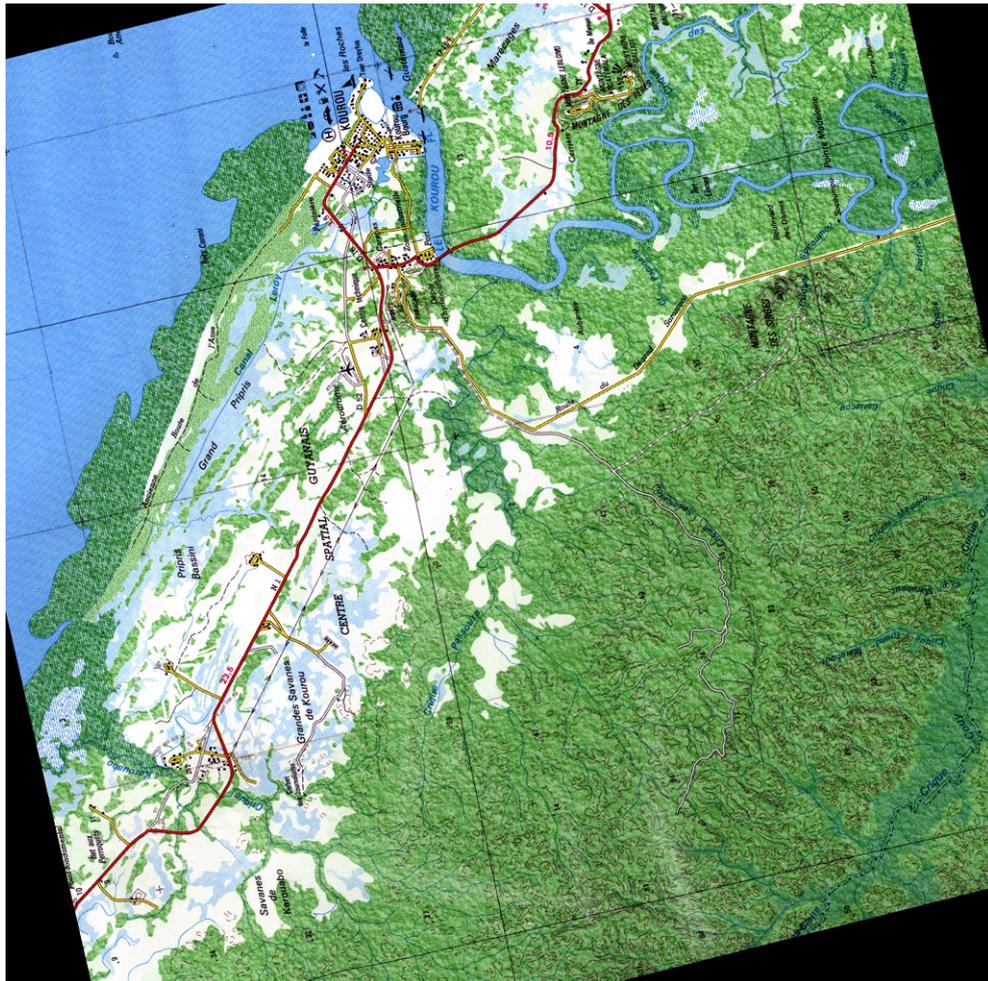


FIG. B.12 – Carte de la région de Kourou ©IGN.

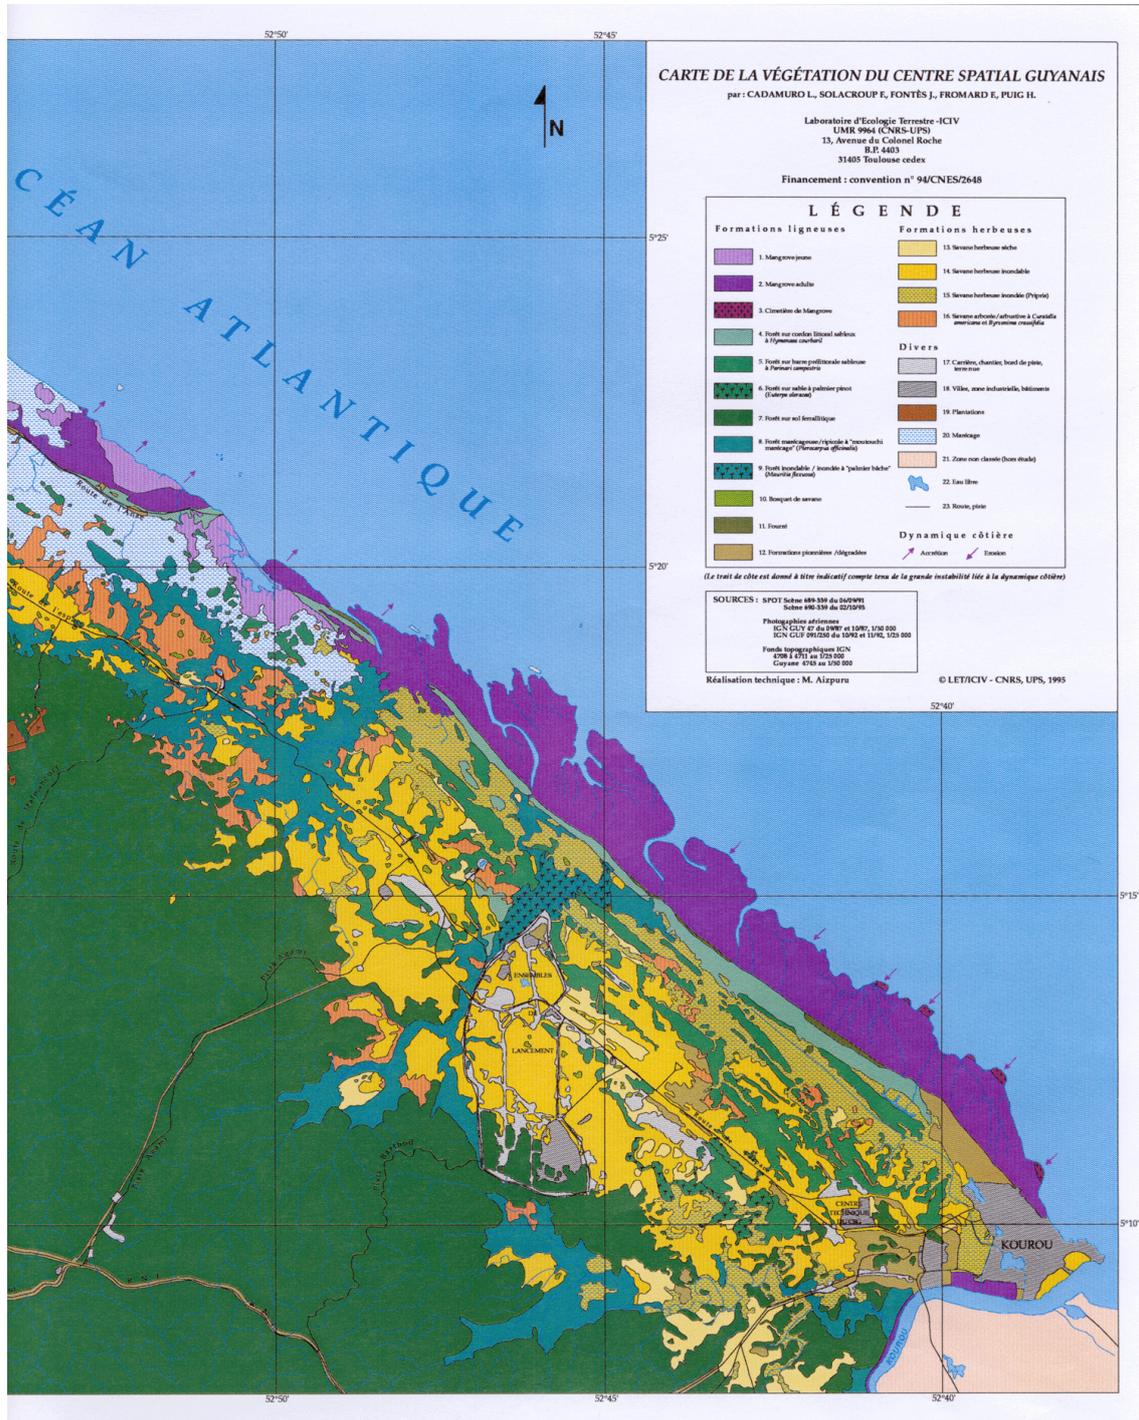


FIG. B.13 – Carte de la végétation entre Kourou et le Centre Spatial Guyanais.

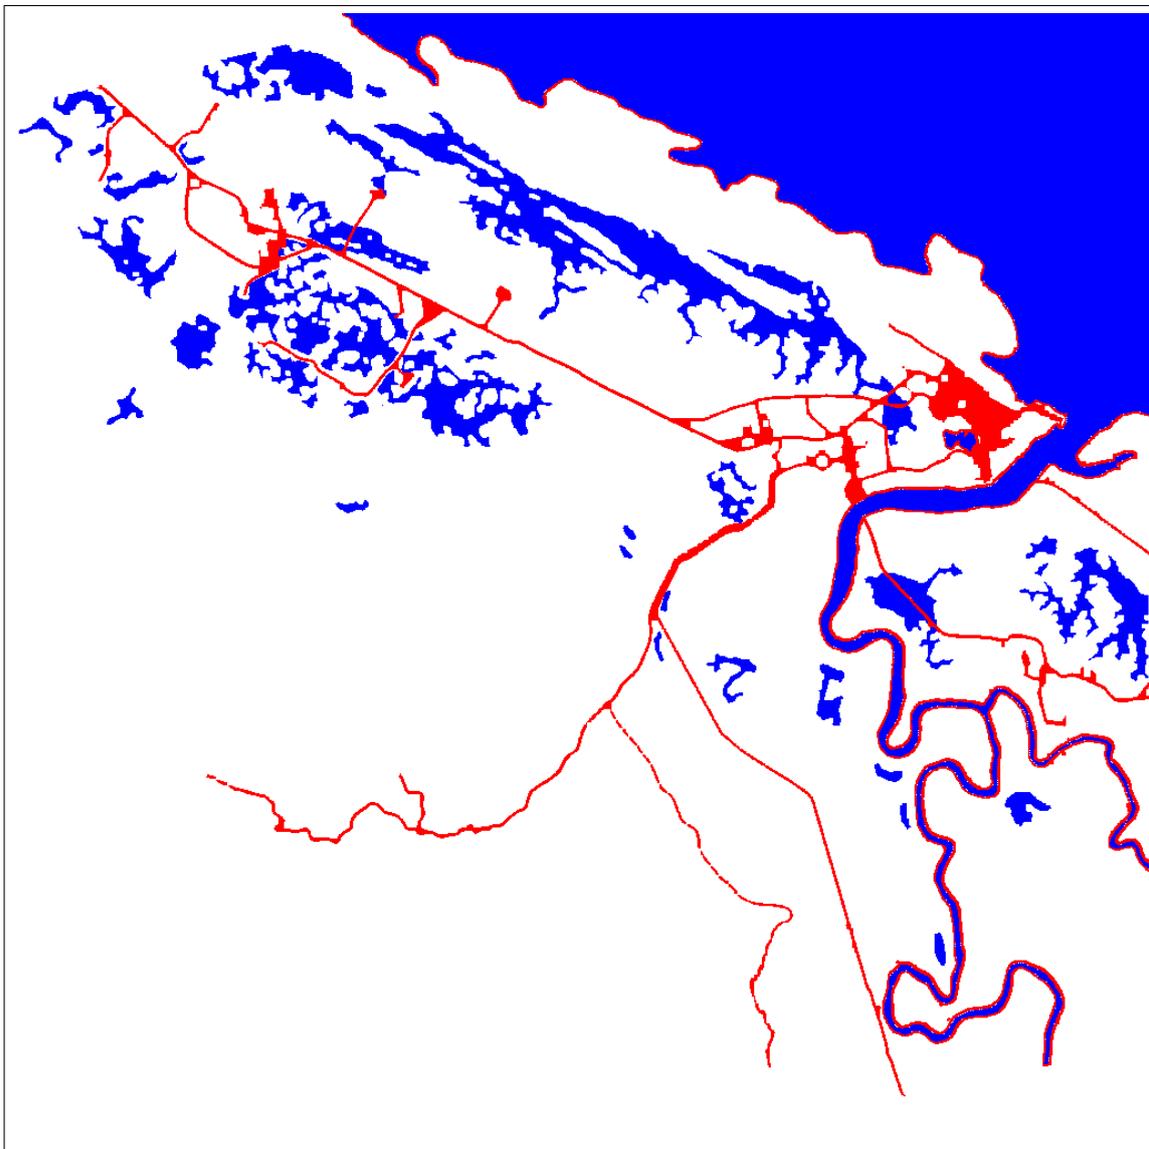


FIG. B.14 – Vérité terrain pour la région du Kourou : bleu - zones de changements temporels ; rouge - zones de structures spatiales stables ; blanc - zones homogènes de point de vue spatial et temporel.

B.3 Région de Douala

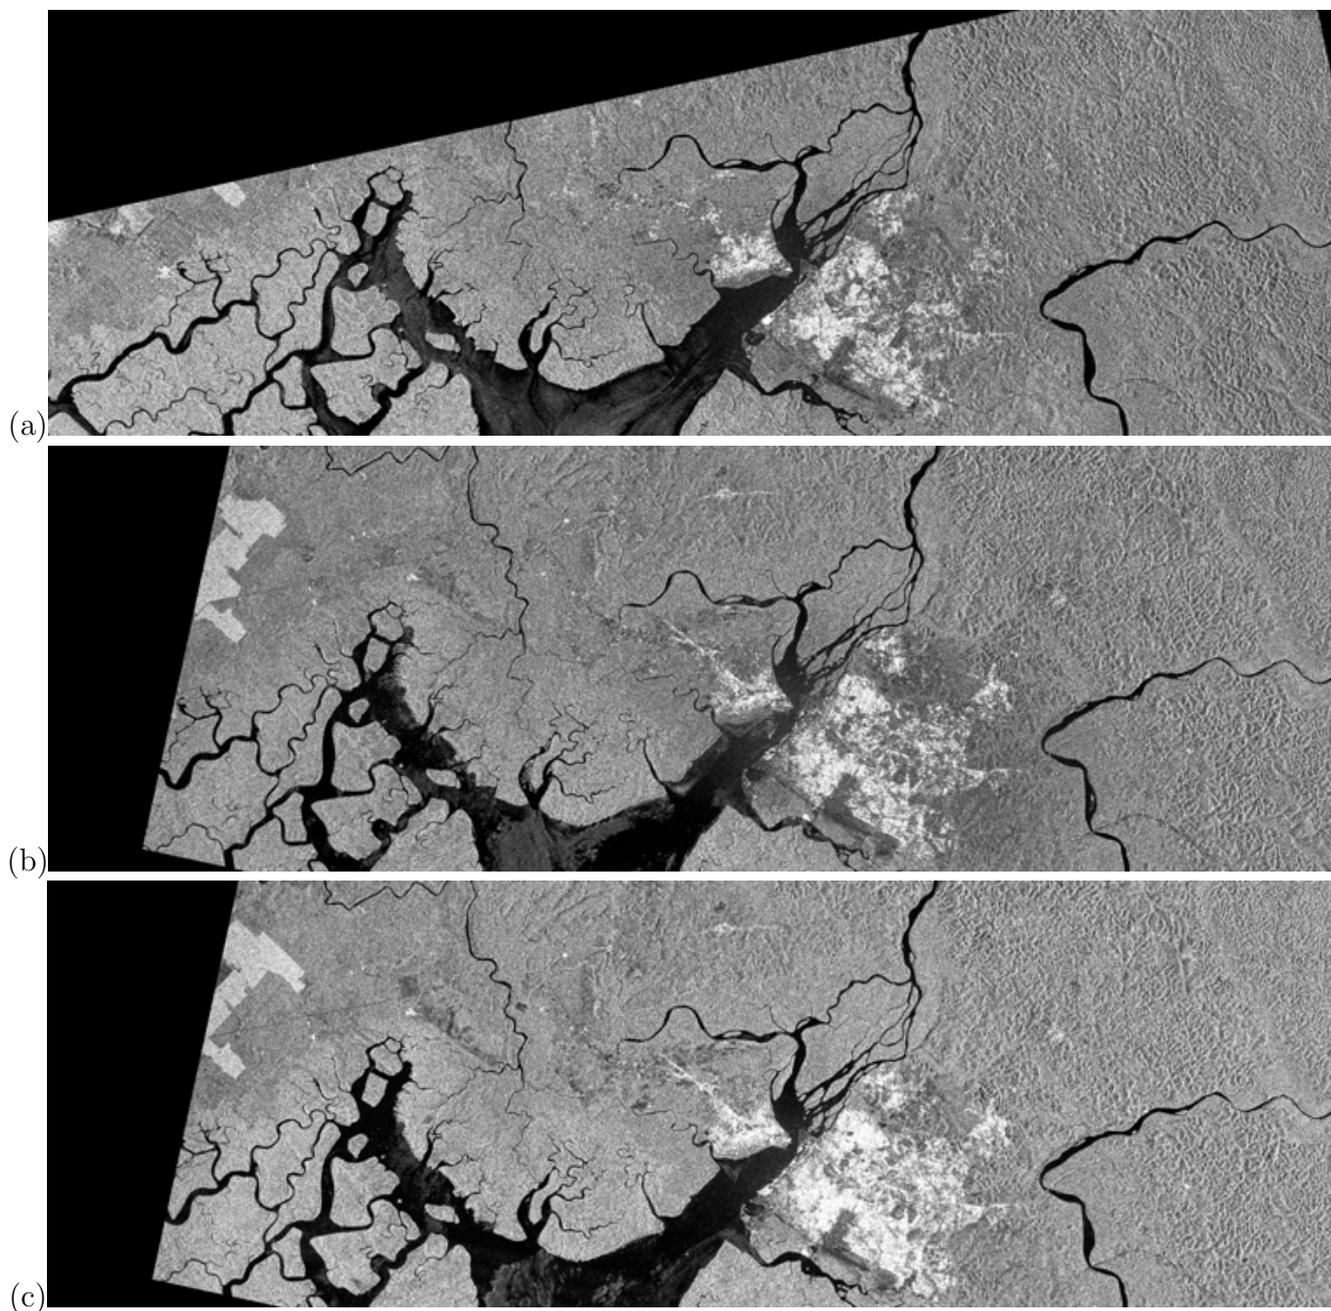


FIG. B.15 – Série de la région Douala : (a) 23 Août 1994, orbite montante ; (b) 4 Décembre 1995, orbite descendante ; (c) 2 Février 1999, orbite descendante.

Annexe C

Annexe technique : Interface *Fusion Floue Symbolique*

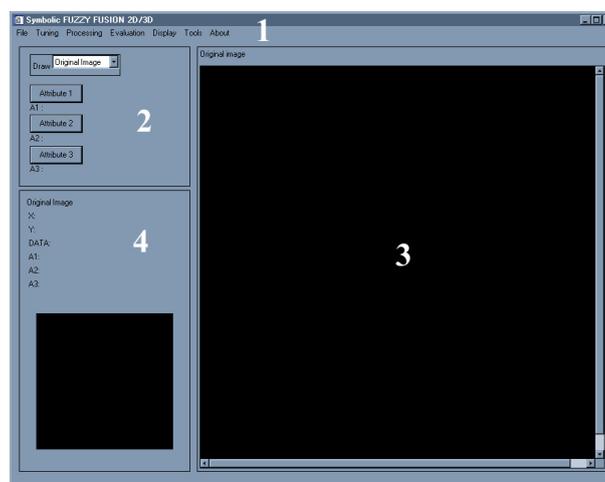
Cette annexe technique présente l'Interface Homme-Machine (IHM) réalisée comme implantation pratique de l'approche proposée dans cette thèse. L'IHM a été mise en œuvre en utilisant le langage IDL (Interactive Data Language), langage développé par Research System Inc. (RSI¹).

C.1 Fenêtre principale

L'IHM est réalisée dans une seule fenêtre sur laquelle différentes fonctionnalités sont disponibles pour l'utilisateur. Au démarrage, l'aspect de l'IHM est celui de la figure C.1. Les composants visibles sont :

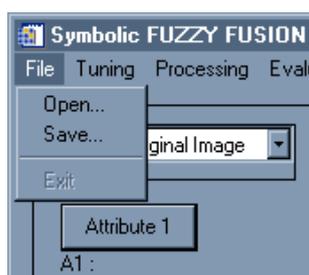
1. Une barre de menus avec différents sous-menus ;
2. Un bloc non-modifiable qui contient une liste pour le choix de différentes visualisations pour les blocs 3 et 4, et trois boutons pour le chargement des attributs ;
3. Un bloc modifiable pour la visualisation des différentes images (originale, d'attribut ou résultat) et pour la visualisation de la représentation de règles (2D ou 3D) ;
4. Un bloc modifiable qui apporte des informations sur le contenu du bloc 3 et contient une sous-fenêtre de visualisation.

¹<http://www.rsinc.com/>

FIG. C.1 – Fenêtre de démarrage de l’IHM *Fusion Floue Symbolique*.

C.1.1 Barre de menus

La barre de menus contient les menus **File**, **Tuning**, **Processing**, **Evaluation**, **Display**, **Tools**, **About**. Le menu **File** (fig. C.2) donne accès aux fonctions d’ouverture de fichiers d’images originales (**File**→**Open...**) et de sauvegarde des images résultats (**File**→**Save...**). Les images qui peuvent être ouvertes sont des images codées sur 8 bits (classiques) ou codées sur 16 bits pour les images RSO du type PRI. Le format de sauvegarde est le format Sun Raster File pour les sorties 8 bits ou le format “propriétaire” (*.imf) pour les sorties de type *float* (images de degré d’appartenance, etc.).

FIG. C.2 – Menu **File**.

Le menu **Tuning**, avec les deux sous-menus 2D et 3D, (fig. C.3) contient les fonctions permettant le passage 2D↔3D pour la représentation des règles (**Tuning** → 2/3D → **Tuning** 2/3DRules) et les fonctions de sauvegarde et chargement des ajustements des règles et des fonctions d’appartenance (**Tuning** → 2/3D → Load/Save 2/3D Rules/MF Tuning). Le sous-menu **Tuning** → 2D a une fonction de ré-initialisation de règles 2D (**Tuning** → 2D →

Reset 2D Rules).

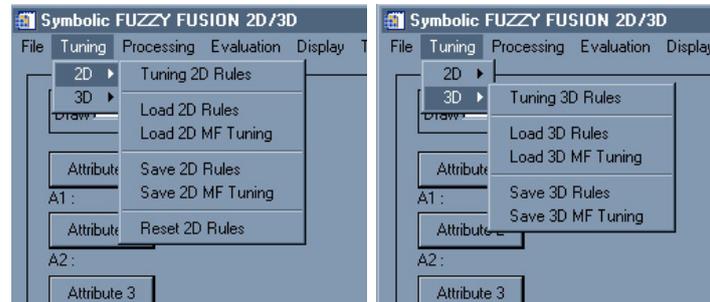


FIG. C.3 – Menu **Tuning**.

Le menu **Processing** contient les principales fonctions de l'IHM *Fusion Floue Symbolique*. Elles sont organisées dans les sous-menus **Region Of Interest**, **Histograms**, **Fusion**.

Les fonctions dans le sous-menu **Region Of Interest** (fig. C.4) sont des fonctions pour la manipulation de régions d'intérêt nécessaires pour l'étape de définition de références pour l'ajustement de paramètres ou pour évaluation de performances.

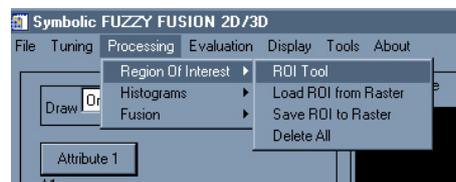


FIG. C.4 – Sous-menu **Processing**→**Region Of Interest**.

La fonction **ROI Tool** ouvre une fenêtre, comme celle de la figure C.5, qui offre des outils pour le tracé de régions d'intérêt.

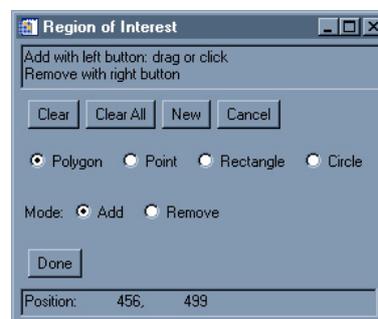


FIG. C.5 – Fenêtre pour la manipulation de régions d'intérêt.

Les fonctions présentes dans le sous-menu **Histograms** (fig. C.6) sont des fonctions de calcul d'histogrammes 2D et 3D à partir des images d'attributs et des régions d'intérêt

tracées par l'utilisateur. Ces histogrammes représentent les distributions conditionnelles des attributs pour les classes données par les régions d'intérêt.

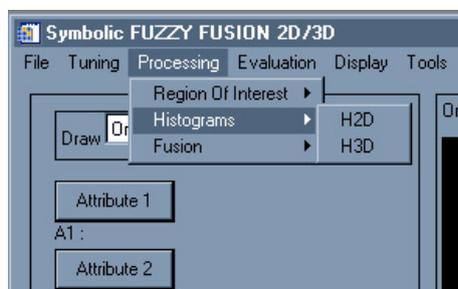


FIG. C.6 – Sous-menu **Processing**→**Histograms**.

Le sous-menu **Fusion** (fig. C.7) contient les deux fonctions de fusion floue de deux attributs (2D) et de trois attributs (3D) qui sont le cœur de l'IHM. Le choix de la méthode de fusion interactive ou semi-supervisée est fait en fonction de l'absence (méthode interactive) ou la présence (méthode semi-supervisée) d'histogrammes conditionnels calculés avec les régions d'intérêt.

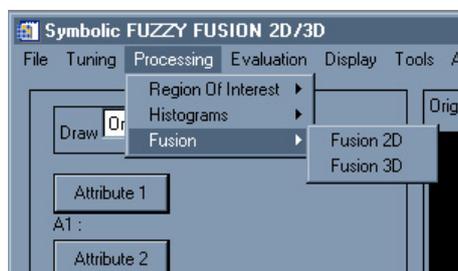
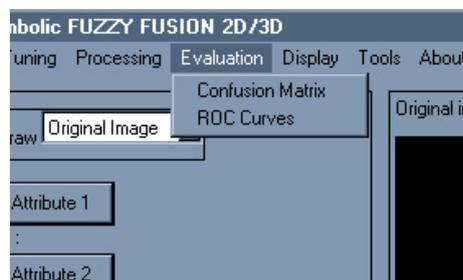


FIG. C.7 – Sous-menu **Processing**→ **Fusion**.

Le menu **Evaluation** (fig. C.8) contient les fonctions d'évaluation de performances utilisées pour évaluer quantitativement un résultat et pour faire évoluer, si nécessaire, le paramétrage du système de fusion.

La méthode des courbes COR (**Evaluation** → **ROC Curves**) fournit une évaluation des degrés d'appartenance aux mots (nom de classe) qui décrivent la sortie et la méthode des matrices de confusion (**Evaluation** → **Confusion Matrix**; fig. C.9) fournit une évaluation de la classification finale (après décision).

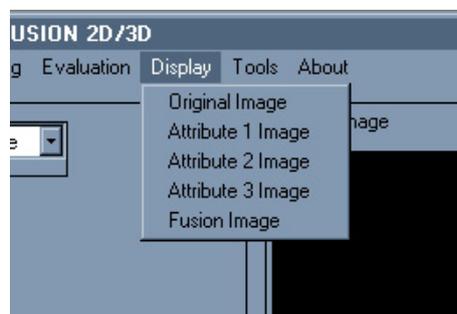
Le menu **Display** (fig. C.10) contient des fonctions pour le changement des blocs 3 et 4 pour la visualisation de différentes images (originale, attributs, résultats). Ces fonctions

FIG. C.8 – Menu **Evaluation**.

Assigned Class\Ground Truth	Class1	Class2	Class3	Total		User Acc. (%)
Class1	157	0	9	166		94.5783
Class2	15	347	2	364		95.3297
Class3	540	472	2877	3889		73.9779
Total	712	819	2888	4419		
Producer Acc. (%)	22.0506	42.3687	99.6191		Overall Acc. (%) =	76.5105
					kappa coef. =	0.417890

FIG. C.9 – Matrice de confusion.

sont les mêmes que les fonctions appelées dans la liste du bloc 2 pour le changement de visualisation des blocs 3 et 4.

FIG. C.10 – Menu **Display**.

C.2 Fenêtres de visualisation/représentation

Les fenêtres de visualisation sont de plusieurs types : fenêtres de visualisation d'images (originales, attributs ou résultats) ou fenêtres de représentation des règles 2D ou 3D. Ces fenêtres sont visibles dans le bloc 3. Le bloc 4 permet d'afficher différentes informations liées à ces fenêtres de visualisation ou représentation.

C.2.1 Fenêtre de visualisation d'images originales

La fenêtre pour la visualisation d'images originales (fig. C.11) donne aux utilisateurs la possibilité de voir les images sur lesquelles les attributs à fusionner sont calculés et de dessiner les zones d'intérêt (utilisées comme aide à l'ajustement de règles ou comme zones de référence pour l'évaluation de performances). La fenêtre proprement dite se trouve sur le bloc 3. Sur le bloc 4 sont disponibles des informations concernant le pixel qui est pointé avec le curseur (souris) dans la fenêtre de visualisation : les coordonnées (X et Y), la valeur de pixel (DATA) et les valeurs des attributs (A1, A2, A3) aux mêmes coordonnées. Une petite fenêtre de visualisation de l'image en entier est présente aussi sur le bloc 4.

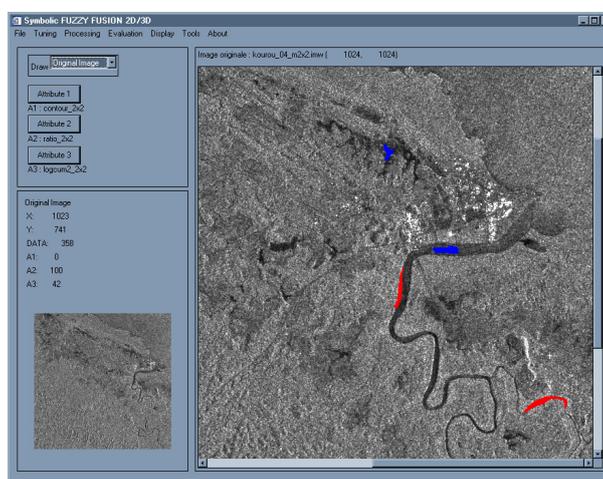


FIG. C.11 – Fenêtres de visualisation d'images originales (image RSO en niveaux de gris) et de sélection de régions d'intérêt (marque de classes en couleur).

C.2.2 Fenêtres de visualisation d'images d'attribut

Les fenêtres de visualisation d'images d'attribut (fig. C.12) sont au nombre de trois et ont le même aspect que la fenêtre de visualisation d'images originales pour les blocs 3 et 4. La différence est qu'il n'est pas possible de visualiser et de sélectionner des zones d'intérêt sur les images d'attribut.

C.2.3 Fenêtre de visualisation des résultats

La fenêtre de visualisation des résultats (fig. C.13) permet de présenter les résultats de la fusion floue. L'image affichée peut être :

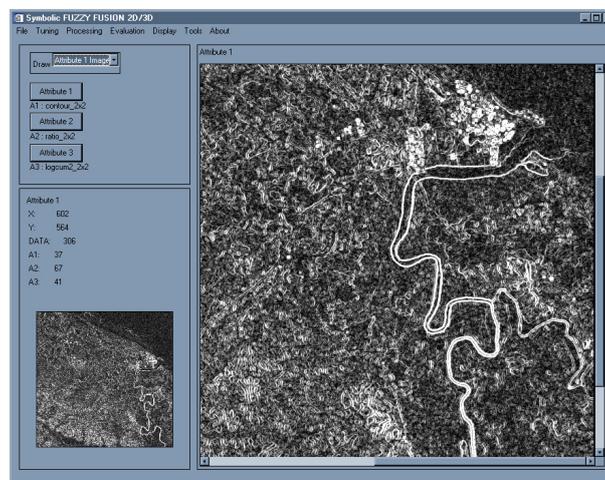


FIG. C.12 – Fenêtre de visualisation d’images d’attribut.

- une image de degré d’appartenance à une classe spécifiée ;
- un seuillage de l’image précédente (α -coupe) ;
- une composition colorée des degrés d’appartenance (si le nombre des classes est inférieur ou égal à trois) ;
- le résultat net de classification finale (maximum de degré d’appartenance).

Les couleurs utilisées pour les régions d’intérêt sont employées pour la représentation des classes de sortie. Le bloc 4 présente seulement la petite fenêtre de visualisation du résultat sur la totalité de l’image.

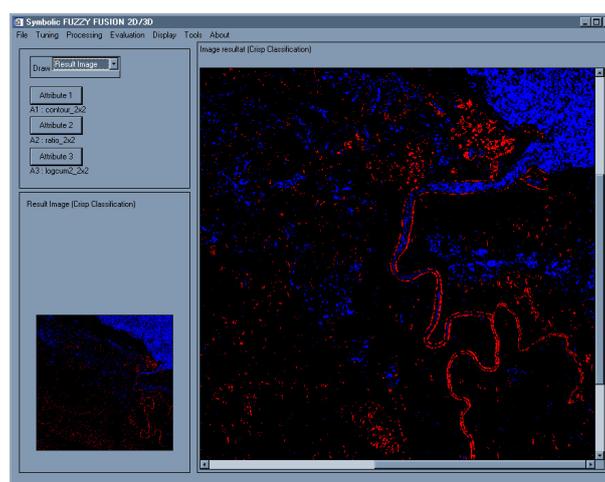


FIG. C.13 – Visualisation du résultat de fusion.

C.2.4 Fenêtre de représentation de règles 2D

La représentation des règles bidimensionnelles (2D; fig. C.14) utilise simultanément les blocs 3 et 4 de l'IHM. Sur le bloc 3 apparaît la fenêtre de règles avec un quadrillage correspondant aux fonctions d'appartenance, et les boutons pour l'appel de différentes fonctions utiles pour l'ajustement de règles. Sur le bloc 4 apparaissent les deux attributs et les fonctions d'appartenance qui les décrivent. Sur les deux axes de la fenêtre de règles et l'abscisses de fonctions d'appartenance sont représentés les intervalles de valeurs d'attributs à fusionner (A1 et A2). Les lignes pointillées vertes correspondent aux valeurs modales des fonctions d'appartenance, tandis que les lignes jaunes sont les intersections des fonctions d'appartenance à la valeur de 0,5.

Le bouton **Adjustment** ouvre la possibilité d'ajuster les paramètres du système flou (les règles et les fonctions d'appartenance) par l'activation des boutons **Table**, **Class1**, **Class2**. Le bouton **Table** permet à l'utilisateur de régler les fonctions d'appartenance par le déplacement de valeurs modales sur la fenêtrés de règles. Les boutons **Class1/2...** donne la possibilité de placer les règles pour deux classes de sortie (le système est actuellement implanté pour 2 ou 3 classes de sortie dont une classe de rejet). Le bouton **Reset Table** est utilisé pour la ré-initialisation des fonctions d'appartenance. Le bouton **Delete Rules** efface les règles antérieurement choisies pour un nouveau réglage du système flou.

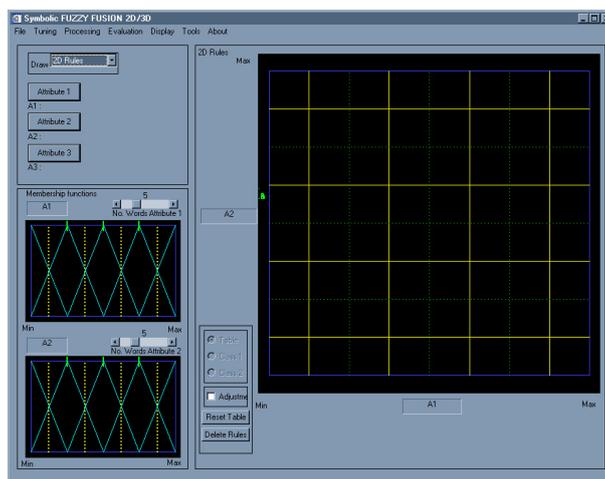


FIG. C.14 – Représentation de règles 2D.

Dans le bloc 4 sont représentées les fonctions d'appartenance pour chaque attribut (A1 et A2). Les mêmes couleurs ont été utilisées : vert pour les valeurs modales, jaune pour l'intersection des fonctions d'appartenance à la valeur de 0,5. Deux barres glissantes donnent

la possibilité de choisir le nombre de mots (entre 3 et 10) pour la description des attributs.

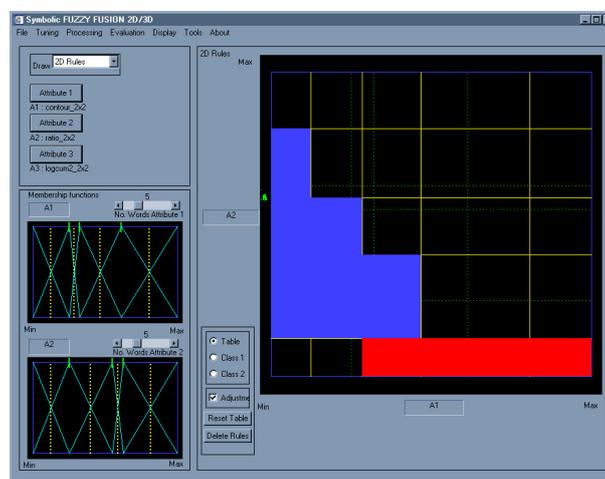


FIG. C.15 – Exemple d’ajustement de règles 2D.

Le réglage des fonctions d’appartenance (fig. C.15) peut être fait soit dans le bloc 3 sur la fenêtre de règles (après le choix du bouton **Adjustment**), soit sur les représentations des fonctions d’appartenance sur le bloc 4, par le déplacement des valeurs modales (lignes vertes). L’activation de règles est fait seulement dans la fenêtre de règles, du bloc 3.

C.2.5 Fenêtre de représentation de règles 3D

La représentation de règles tri-dimensionnelles utilise également les blocs 3 et 4 de l’IHM (fig. C.16). Dans le bloc 3 sont présents la fenêtre de règles 3D et des boutons pour le choix de différentes fonctions d’ajustement. Comme pour le cas 2D, les axes correspondent aux trois attributs à fusionner avec leurs intervalles de valeurs. Les lignes représentatives pour le cas 2D (les valeurs modales et les intersections à 0,5) se transforment ici en plans. Les couleurs utilisées sont les mêmes que pour le cas 2D. Dans le bloc 4 est donnée une représentation 2D du plan sélectionné dans la fenêtre 3D, qui aide au positionnement des règles et des fonctions d’appartenance 3D.

Les boutons visibles dans le bloc 3 (fig. C.17) ont les fonctions suivantes. Le bouton **Grid 3D** “allume” toutes les lignes sur tous les plans séparateurs afin d’améliorer la visualisation des règles. Le bouton **Adjust** active les boutons pour le réglage des fonctions d’appartenance (**MF**), le positionnement de règles pour les deux classes recherchées (**Rules Class1** et **Rules Class2**) et le choix du plan accessible pour l’ajustement (**X/Y/Z Planes**). Le

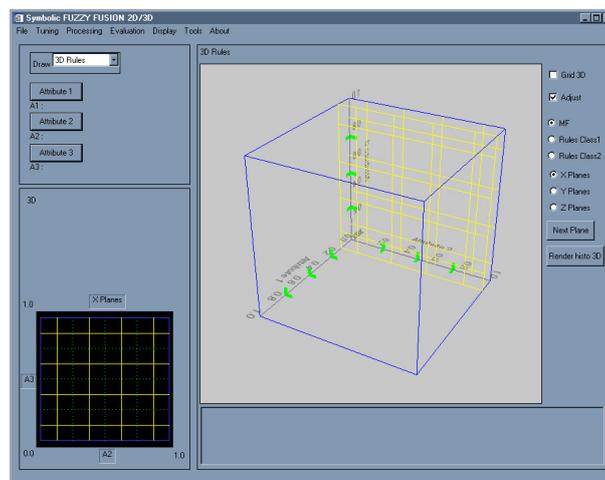


FIG. C.16 – Fenêtre de représentation de règles 3D.

bouton **Next Plane** change la position du plan sélectionné pour l'ajustement. Le bouton **Render histo 3D** visualise les données 3D utilisées pour le positionnement des règles, en s'appuyant sur des zones de référence données par l'utilisateur.

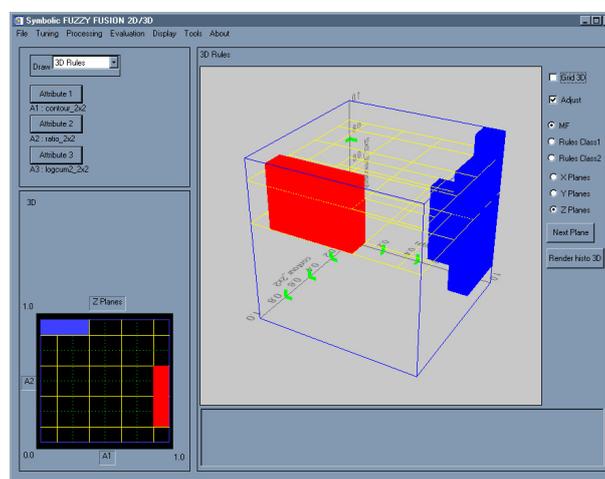


FIG. C.17 – Exemple d'ajustement de règles 3D.

Le réglage des fonctions d'appartenance et le positionnement de règles (fig. C.17) peut être fait seulement dans le bloc 4 sur la représentation 2D du plan sélectionné dans le bloc 3.

C.3 Fonctionnement de l'IHM

L'utilisation de l'IHM se fait en deux parties. Une première partie est l'initialisation ou l'ajustement du système avec réglage de fonctions d'appartenance et positionnement de règles. La deuxième partie est celle de fusion et d'évaluation de performances.

Dans un premier temps, après le chargement de l'image originale et d'images d'attributs, l'utilisateur trace les zones de référence pour les classes de sortie (dans la fenêtre d'image originale, fig. C.11) et donne l'ensemble de règles floues 2D (fig. C.15) ou 3D (fig. C.17) qui traduit sa connaissance. Les zones de référence sont dessinées dans une fenêtre comme celle présentée dans la figure C.11). Ce sont les zones où l'utilisateur connaît les caractéristiques qui définissent les classes. Le but de cette étape est de choisir dans l'image les régions ayant les mêmes caractéristiques.

Après avoir fourni ces données d'entrée (les régions d'intérêt et les règles décrivant ces régions) le système de fusion possède assez d'informations pour réaliser la fusion. Un premier résultat est obtenu sans réglage spécifique des fonctions d'appartenance. Leur initialisation correspond à des valeurs modales équidistantes. Un meilleur ajustement des fonctions d'appartenance par l'utilisateur permet ensuite d'obtenir de meilleurs résultats.

Dans un deuxième temps, l'utilisateur peut choisir de faire évoluer les paramètres pour améliorer la détection conformément à son évaluation qualitative. Si des zones de référence ont été tracées, l'évaluation de performances peut également être quantitative à l'aide de courbes COR réalisées en seuillant les images de degré d'appartenance aux classes recherchées, ou à l'aide de la matrice de confusion du résultat net. Cette étape est nécessaire car les attributs d'entrée ont une dynamique différente selon les zones d'intérêt. Ce réglage doit pouvoir être effectué facilement par l'utilisateur. Pour positionner à leur convenance les règles et les fonctions d'appartenance 2D (fig. C.15) et 3D (fig. C.17), les utilisateurs ont la possibilité de déplacer les lignes horizontales et verticales sur la fenêtre de visualisation de règles 2D (fig. C.15) ou les plans horizontaux ou verticaux sur la fenêtre de visualisation de règles 3D (fig. C.16) ; les nouvelles intersections entre les fonctions d'appartenance sont ainsi calculées automatiquement.

Annexe D

Classification non-supervisée : C-moyennes floues

Les C-moyennes floues¹ [BEZDEK, 1973],[BEZDEK, 1980] sont un cas particulier d’algorithmes de classification non-supervisée basés sur la minimisation d’une fonction objectif. C’est aussi une méthode métrique, car le critère minimisé fait intervenir des distances séparant chaque point des prototypes des différentes classes. Par la suite, nous rappelons l’algorithme général des C-moyennes floues FCM et son application à la classification d’images multi-composantes. Pour une présentation détaillée de différentes variantes de cet algorithme on se rapportera à la thèse de Khodja [KHODJA, 1997].

D.1 L’algorithme des C-moyennes floues

L’algorithme des c-moyennes floues effectue une optimisation itérative en recherchant de façon approximative les minima d’une fonction d’erreur. Il existe toute une famille de fonctions d’erreur associées à cet algorithme qui se distinguent par des valeurs différentes prises par un paramètre réglable, m , appelé indice flou (*fuzzy index*) et qui détermine le degré de flou de la partition obtenue.

Soit un ensemble de NbP points (vecteurs) $x_k, k \in [1, NbP], x_k \in \mathbb{R}^p$, à classer selon C classes, et soit ν le C -uplet :

$$\nu = (\nu_1, \nu_2, \dots, \nu_c), \quad (D.1)$$

où $\forall i \in [1, C], \nu_i \in \mathbb{R}^p$ est un vecteur à p composantes qui représente le centroïde de la i^{eme}

¹engl. Fuzzy C-Means (FCM)

classe.

La fonction objectif associée aux C -moyennes floues, J_m est définie par :

$$J_m(U, \nu) = \sum_{k=1}^{NbP} \sum_{i=1}^c (u_{ik})^m (d_{ik})^2 \quad (D.2)$$

où pour tout i et pour tout k , $(d_{ik})^2 = \|x_k - \nu_i\|^2$ et $\|\cdot\|$ est une norme associée à un produit scalaire défini dans \mathbb{R}^p . On peut aussi écrire :

$$d_{ik}^2 = d^2(x_k - \nu_i) = (x_k - \nu_i)^T A(x_k - \nu_i), \quad (D.3)$$

où A est une matrice $p \times p$ définie positive. Enfin, l'indice flou m , doit être strictement supérieur à 1 : $m \in]1, +\infty[$. Le carré de la distance séparant un vecteur x_k d'un centre ν_i , $(d_{ik})^2$, est pondéré par la puissance m du degré d'appartenance de la donnée x_k à la classe i : $(u_{ik})^m$. J_m est donc une erreur quadratique généralisée et sa minimisation conduit, théoriquement à la partition optimale. Les C -moyennes floues produisent une C -partition floue qui est une approximation de la partition optimale de l'ensemble de données $X = \{x_1, x_2, \dots, x_{NbP}\}$.

L'algorithme, dont la convergence a été étudiée par Bezdek [BEZDEK, 1980], [BEZDEK, 1981], peut être décrit par les étapes suivantes :

1. Fixer le nombre de classes C tel que $2 \leq C \leq NbP$, NbP étant le nombre de données. Fixer une valeur pour m telle que $m > 1$. Choisir une norme $\|\cdot\|$ dans \mathbb{R}^p : $\|x - \nu\|^2 = (x - \nu)^T A(x - \nu)$. Le plus souvent A est la matrice identité qui correspond à la distance euclidienne.
2. Initialiser la C -partition floue en donnant des valeurs quelconques (éventuellement spécifiques si l'information *a priori* le permet) aux éléments de la matrice de départ correspondante $U^{(0)}$ vérifiant :

$$\forall k \in \{1, 2, \dots, NbP\}, \sum_{i=1}^C u_{ik}^{(0)} = 1. \quad (D.4)$$

3. Initialiser le compteur de boucle : $b=0$.
4. Calculer les C centroïdes des classes $\nu_i^{(b)}$, $1 \leq i \leq C$, en utilisant U^b à l'aide de la formule suivante :

$$\nu_i^{(b)} = \frac{\sum_{j=1}^{NbP} (u_{ij}^{(b)})^m \cdot x_j}{\sum_{j=1}^n (u_{ij}^{(b)})^m} \quad (\text{D.5})$$

5. Mettre à jour la matrice U : calculer la nouvelle matrice de degrés d'appartenance $U^{(b+1)}$ comme suit. Pour $k=1$ allant jusqu'à NbP ,

(a) Chercher I_k et \bar{I}_k :

$$I_k = \{i \in [1, C] / 1 \leq i \leq C \text{ et } d_{ik} = \|x_k - \nu_i\| = 0\}, \quad (\text{D.6})$$

$$\bar{I}_k = \{1, 2, \dots, x\} - I_k, \quad (\text{D.7})$$

(b) Pour la $k^{\text{ème}}$ donnée x_k , calculer les nouveaux degrés d'appartenance selon que l'on est dans l'un ou l'autre des deux cas suivants :

i. Si $I_k = \phi$ (ensemble vide) :

$$u_{ik} = \frac{1/(d(x_k, \nu_i))^{2/(m-1)}}{\sum_{i=1}^C 1/(d(x_k, \nu_i))^{2/(m-1)}}. \quad (\text{D.8})$$

ii. Sinon pour tout $i \in \bar{I}_k$, $u_{ik} = 0$, et pour tout $i \in I_k$, fixer une (des) valeur(s) pour u_{ik} de telle sorte que :

$$\sum_{i \in I_k} u_{ik} = 1. \quad (\text{D.9})$$

(c) Incrémenter k et aller à l'étape (a).

6. Comparer $U^{(b)}$ et $U^{(b+1)}$ à l'aide d'une norme matricielle : si $\|U^{(b+1)} - U^{(b)}\| < \varepsilon$ arrêter l'algorithme, sinon, incrémenter b et aller à l'étape 4.

ε est un nombre réel pré-défini par l'utilisateur et qui sert dans le critère d'arrêt basé sur la distance séparant les matrices calculées aux itérations $(b+1)$ et (b) .

L'étape (5-b) fait intervenir deux cas. Dans le premier cas, (i), aucun centroïde de classe ne correspond avec la donnée x_k . Dans le second cas, (ii), certains centroïdes de classe sont identiques à x_k . La formule générale utilisée dans (i) n'est plus applicable et le point k est attribué aux classes de centroïdes identiques à x_k .

Dans le cas simple de données mono-dimensionnelles ($p=1$), on voit que pour minimiser le critère défini dans (D.2), la dérivée partielle par rapport aux centres doit s'annuler :

$$\frac{\partial J_m}{\partial \nu_i} = 0 \quad \forall i = 1, 2, \dots, C \quad (\text{D.10})$$

Soit, dans le cas de la distance euclidienne :

$$\sum_{j=1}^{NbP} 2u_{ij}^m (\nu_i - x_j) = 0 \quad \forall i = 1, 2, \dots, C \quad (\text{D.11})$$

Ou, encore :

$$\sum_{j=1}^{NbP} u_{ij}^m \nu_i = \sum_{j=1}^{NbP} u_{ij}^m x_j \quad \forall i = 1, 2, \dots, C \quad (\text{D.12})$$

Le repositionnement des centroïdes donné par la relation (D.5) se déduit aisément de l'égalité (D.12).

D.2 Application aux images multi-composantes

Lorsque les données d'entrée sont structurées sous la forme de N images initiales, l'objectif est de chercher une seule image de pixels classifiés en considérant, pour le calcul des coefficients d'appartenance et des centroïdes, toutes les composantes de la coordonnée courante. Cela signifie que les pixels des N images d'entrée sont des vecteurs à $p = N$ composantes et on dispose de $NbP = \dim X \cdot \dim Y$ points à classer où $\dim X$ et $\dim Y$ sont les dimensions des images.

L'algorithme FCM s'applique alors en itérant les étapes 1 à 6 décrites précédemment jusqu'à ce que le critère d'arrêt soit satisfait. Les C ensembles de degrés d'appartenance peuvent être visualisés comme C images de degrés d'appartenance aux différentes classes et forment une classification floue. Une décision de type "maximum des degrés d'appartenance" peut être prise en chaque pixel pour obtenir une classification nette sous la forme d'une seule image (le label de la classe retenue en chaque pixel).

Les résultats de classification obtenus par l'algorithme automatique des C -moyennes floues présenté ci-dessus, sont utilisés dans la section 6.3, à titre de comparaison avec ceux obtenus par la méthode de fusion floue interactive présentée en la section 5.3.

Annexe E

Classification supervisée : Machines à Vecteurs de Support

Les Machines à Vecteurs de Support (SVM) peuvent s’appliquer à des problèmes de classification supervisée. Proposées initialement par Vladimir Vapnik [VAPNIK, 1979], elles sont en forte concurrence avec les réseaux de neurones pour la reconnaissance de formes et montrent des hautes performances dans des applications pratiques. Les SVM sont basées sur quelques idées simples et sont un bon exemple des méthodes fondées sur le principe “apprentissage après l’exemple”.

Les SVM sont des méthodes linéaires dans un espace transformé (appelé *feature space* en anglais) de grande dimensionnalité qui est lié à l’espace d’entrée de façon non-linéaire. En pratique elle n’implique aucun calcul dans l’espace transformé. Par l’utilisation des noyaux, tous les calculs nécessaires sont exécutés directement dans l’espace d’entrée. Pour la classification, les SVM fonctionnent en trouvant un hyperplan de séparation optimal dans l’espace transformé. L’hyperplan sera choisie pour maximiser la marge, c’est-à-dire avoir la plus grande distance de l’hyperplan aux plus proches échantillons de deux classes séparées.

E.1 Machines à vecteurs de support (SVM)

Les SVM ont comme entrée de vecteurs multi-dimensionnels $x \in \mathbb{R}^{NbA}$ qui peuvent être des données, des mesures, des attributs, etc. La sortie est binaire et peut prendre des valeurs dans l’ensemble : $y \in \{-1, 1\}$.

La méthode de classification est supervisée en deux étapes :

1. **Apprentissage** : recherche du classifieur $f : x \rightarrow y = f(x)$ qui sépare l'espace en deux régions (pas forcément connexes) à partir d'un ensemble de données d'apprentissage : $\{(x_i, y_i), i = 1..NbP\}$;
2. **Généralisation** : application du classifieur à l'ensemble des données.

Un problème peut apparaître comme un problème d'optimisation, c'est-à-dire comment trouver la *meilleure* frontière de décision sans tomber dans les cas de sur- ou sous-apprentissage (cf. fig. E.1). , de sur-apprentissage () est .

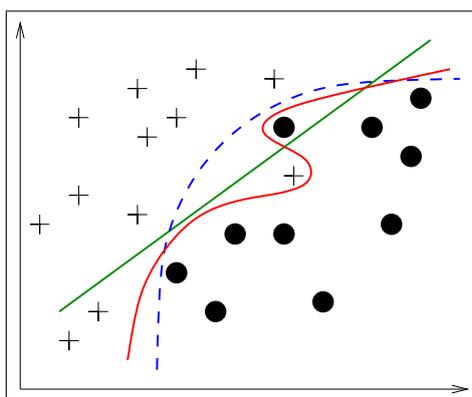


FIG. E.1 – Exemple de sur-apprentissage (classifieur de haut degré - rouge) et sous-apprentissage (classifieur linéaire - vert) par rapport à un apprentissage optimal (bleu).

E.1.1 Principe des SVM

Nous rappelons très brièvement les principes de SVM (fig. E.2) :

- Recherche d'un classifieur à valeurs réelles : $f(x) \in \mathbb{R}$ et décision (classe) donnée par le signe de $f(x)$: $y = \text{sgn}(f(x))$;
- Transformation non-linéaire de l'espace d'entrée $x \rightarrow \Phi(x)$ avec l'objectif de rendre les données séparables dans l'espace transformé;
- Choix d'un séparateur linéaire (dans l'espace transformé) *optimal*, c'est-à-dire un hyperplan qui classe correctement les données et se trouve le plus loin possible de tous les points d'apprentissage.

E.1.2 Recherche de l'hyperplan séparateur optimal

Le modèle linéaire :

$$f(x) = \langle w | x \rangle + b$$

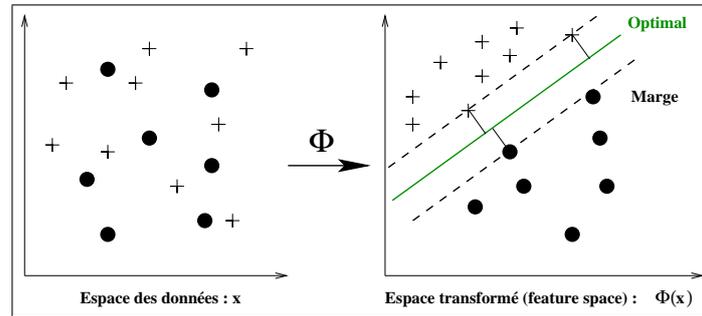


FIG. E.2 – Principe des SVM.

conduit à rechercher un hyperplan séparateur (frontière de décision) défini par :

$$\langle w | x \rangle + b = 0$$

La distance d'un point au plan w est donnée par :

$$d(x) = \frac{|\langle w | x \rangle + b|}{\|w\|}$$

La maximisation de la marge équivaut à la minimisation de $\|w\|$ sous contrainte.

La solution est de forme : $w = \sum_{i=1}^{N_p} \alpha_i y_i x_i$

Seuls les α_i correspondants aux points les plus proches sont non-nuls. Ces points (x_i, y_i) sont appelés vecteurs de supports.

E.1.3 Fonction noyau

Les données étant rarement linéairement séparables dans l'espace initial, la fonction de décision :

$$f(x) = \sum_{i=1}^{N_p} \alpha_i y_i \langle x_i | x \rangle + b$$

est recherchée dans l'espace transformé : $x \rightarrow \Phi(x)$

La solution est alors de la forme :

$$f(x) = \sum_{i=1}^{N_p} \alpha_i y_i \langle \Phi(x_i) | \Phi(x) \rangle + b$$

Elle ne dépend que du produit scalaire dans l'espace transformé $\langle \Phi(x_i) | \Phi(x) \rangle$. La transformation s'effectue par le choix d'une fonction noyau (kernel) k (sans expliciter Φ) :

$$k(x, x') = \langle \Phi(x) | \Phi(x') \rangle$$

E.1.4 Exemple de fonction noyau

Un exemple de fonction noyau est le suivant :

$$x = (x_1, x_2) \in \mathbb{R}^2 \quad \Phi(x) = (x_1^2, \sqrt{2}x_1x_2, x_2^2) \in \mathbb{R}^3$$

Dans l'espace transformé :

$$\langle \Phi(x) | \Phi(x') \rangle = \dots = (\langle x | x' \rangle)^2$$

ce qui permet le calcul direct de $\langle \Phi(x) | \Phi(x') \rangle$ par le noyau $k(x, x') = (\langle x | x' \rangle)^2$

Les noyaux usuels sont :

- Linéaire : $k(x, x') = (\langle x | x' \rangle)$
- Polynomial : $k(x, x') = (\langle x | x' \rangle)^d$ ou $(c + \langle x | x' \rangle)^d$
- Gaussien (Radial Basis Function) : $k(x, x') = e^{-\|x-x'\|^2/\sigma}$
- Laplacien : $k(x, x') = e^{-\|x-x'\|/\sigma}$

E.2 Application des SVM à la classification d'images

La classification supervisée par SVM étant de plus en plus répandue dans de nombreux domaines d'application, des codes sources sont aujourd'hui disponibles. Pour appliquer cette méthode à la fusion d'attributs, nous nous sommes appuyés sur les fonctions d'apprentissage et de classification SVM^{light} de Thorsten Joachims¹. SVM^{light} est une implantation de l'algorithme SVM de Vapnik [VAPNIK, 1995], fortement optimisée [JOACHIMS, 1998b], [JOACHIMS, 1999], [JOACHIMS, 2000], qui peut manipuler des données d'apprentissage et de test de dimensions importantes (considérant le cas où on doit classifier un ensemble de 3 images, dimensions 2048 × 2048 ; alors on a 4.194.304 vecteurs, chacun avec 3 composantes) [JOACHIMS, 1998a].

Dans la chaîne de traitement pour la classification d'images avec les SVM, nous distinguons 3 étapes fondamentales : l'apprentissage, la classification binaire et la décision pour obtenir une classification multi-classes à partir de classifications binaires. Pour obtenir une classification avec plus de deux classes, avec l'algorithme SVM qui réalise des classifications binaires, nous adoptons la stratégie "un-contre-tous" en effectuant NbC classifications binaires suivies par une étape de décision pour obtenir la classification multi-classes.

¹<http://svmlight.joachims.org/>

L'étape d'apprentissage, pour la classification binaire, a pour but de trouver l'hyperplan de séparation optimal entre une des classes et l'ensemble des autres classes. L'hyperplan est trouvé dans l'espace transformée, à partir des vecteurs d'apprentissage. Les vecteurs de support qui résultent sont utilisés pour la classification. Dans l'étape de classification, nous calculons *la position* et *la distance* de tous les pixels de l'image initiale à l'hyperplan de séparation optimal (pour un ensemble de vecteurs support). Dans chaque classification binaire, nous obtenons, pour chaque pixel de l'image, une position par rapport à l'hyperplan, donnée par le signe de résultat, et une distance, donnée par la valeur absolue du résultat. Si le pixel est du même côté de l'hyperplan que la classe recherchée, alors la distance est positive; si non, elle est négative. Plus la distance à l'hyperplan est grande, plus le pixel appartient à une classe si il est du bon côté, moins il appartient à cette classe si il est de l'autre côté.

Après avoir obtenu NbC images "floues", les résultats des NbC classifications "un-contre-tous" doivent être combinés pour obtenir la classification finale nette en NbC classes. La solution classique pour déterminer la classe gagnante pour chaque coordonnée (chaque pixel), est de trouver la classe avec la distance positive maximale, et d'attribuer le pixel de sortie à cette classe. Pour chaque coordonnée, nous pouvons avoir, dans les NbC images de distance, aucun, un ou plusieurs éléments supérieurs à zéro. Lorsque nous avons plusieurs pixels positifs, nous faisons le choix de la plus grande distance positive.

Lorsque les zones d'apprentissage pour certaines classes ne sont pas suffisamment générales ou les classes ne sont pas suffisamment séparables, nous pouvons avoir des pixels avec toutes les distances négatives. Ces pixels forment une classe supplémentaire, appelée *classe de rejet*. L'information contenue dans cette classe, peut être utile pour évaluer la qualité du masque d'apprentissage. Si les zones d'apprentissage ne sont pas bien choisies, les performances de classification diminuent sensiblement.

Pour classifier aussi cette classe de rejet, obtenue par une décision brute, nous appliquons un raffinement supplémentaire proposé par Florea [FLOREA, 2003]. Le choix fait est d'allouer le pixel à la classe pour laquelle la distance est la moins négative, c'est-à-dire la plus proche de zéro (la classe pour laquelle le pixel est "le moins" rejeté).

Un problème qui peut apparaître avec ce raisonnement est qu'une fausse classe peut être déclarée gagnante. Cela arrive, par exemple, quand deux classes se disputent une frontière et cette frontière comporte un dégradé. Il arrive qu'au milieu de ce dégradé les données sont loin des vecteurs d'apprentissage des deux classes en compétition, et deviennent plus proche d'une troisième classe.

Pour corriger ce défaut, la solution retenue consiste à imposer une condition supplémentaire, plus exactement, une condition de voisinage (ou contextuelle). Nous regardons dans le voisinage, quelles sont les classes qui sont en compétition pour cette frontière et nous prenons la distance la moins négative parmi ces deux classes. On élimine ainsi la possibilité de choisir une classe fausse.

La méthode de classification supervisée présentée dans cette annexe a été utilisée dans le chapitre 6, section 6.3 dans la comparaison des résultats pour l'évaluation de performances.

Annexe F

Évaluation des performances

Une méthode simple pour évaluer une classification est de calculer l'aire totale de chaque classe trouvée sans prendre en compte la localisation de la classe. La comparaison entre les valeurs des aires dans la classification et dans la référence tend vers une compensation entre les erreurs d'omission (omettre de la classe des éléments qui doivent y être) et les erreurs de commission ("co-mettre" dans la classe des éléments qui ne doivent pas y être) qui vont se compenser donnant des bons totaux. Cependant, aucune information sur la localisation des classes ou combien la classification approche ou non la référence ne sort de ce type d'évaluation.

Pour faire une évaluation plus précise qui dépasse les inconvénients antérieurs et permette d'évaluer une classification non seulement globalement mais aussi en tenant compte des différentes classes, un outil très utilisé est la matrice d'erreur ou la matrice de confusion.

F.1 Matrice de confusion

La matrice de confusion est un tableau à double entrée qui représente les nombres des pixels attribués à une certaine classe dans une classification relatifs aux nombres des pixels attribués à une certaine classe dans une autre classification. En général, une de ces classifications est considérée comme étant correcte (référence). En imagerie satellitaire cette référence est souvent générée en utilisant des photos aériennes, des cartes ou des mesures, et des observations faites sur le terrain. Usuellement, les colonnes représentent les données de référence, tandis que les lignes représentent la classification générée à partir des données de télédétection.

La matrice de confusion est un très bon moyen pour représenter la précision d'une clas-

sification parce que les précisions individuelles pour chaque classe sont données avec les erreurs d'inclusion (erreurs de commission) et les erreurs d'exclusion (erreurs d'omission) présentes dans la classification. L'erreur de commission est faite quand un pixel qui n'appartient pas à une classe est inclus dans la classe, et l'erreur d'omission quand un pixel qui devait appartenir à une classe est exclu de la classe. Chaque erreur de classification entraîne à la fois une erreur de commission et une erreur d'omission.

En plus des erreurs de commission et d'omission, la matrice de confusion peut être utilisée pour calculer d'autres mesures de précision comme la précision globale (overall accuracy), la précision du réalisateur (producer's accuracy) et la précision de l'utilisateur (user's accuracy).

La précision globale est la somme sur la diagonale principale (les pixels classifiés correctement dans chaque classe) divisée par le nombre total de pixels comptabilisés dans la matrice de confusion. Dans les applications de télédétection un niveau de 85% est, en général, jugé satisfaisant pour la précision globale. Les précisions du producteur et de l'utilisateur représentent les précision individuelles pour chaque classe et se retrouvent respectivement sur la dernière ligne et la dernière colonne.

Référence \ Classification	1	2	...	k	...	n_{i+}
1	n_{11}	n_{12}	...	n_{1k}	...	n_{1+}
2	n_{21}	n_{22}	...	n_{2k}	...	n_{2+}
⋮						
k	n_{k1}	n_{k2}	...	n_{kk}	...	n_{k+}
⋮						
n_{+j}	n_{+1}	n_{+2}	...	n_{+k}	...	n

TAB. F.1 – Exemple de matrice de confusion.

Les formules mathématiques utilisées pour la matrice de confusion sont données en suite. Supposons que NbP pixels sont distribués dans C^2 cases où chaque pixel est affecté à la fois dans une des C classes des données classifiées (les lignes), et dans une des C classes dans la référence (les colonnes). Notons n_{ij} le nombre des pixels tombés dans la classe i ($i = 1, 2, \dots, C$) pour la classification et dans la classe j ($j = 1, 2, \dots, C$) pour la référence (Tab. F.1).

Le nombre des pixels dans la classe i pour la classification est :

$$n_{i+} = \sum_{j=1}^C n_{ij} \quad (\text{F.1})$$

et le nombre des pixels dans la classe j pour la référence :

$$n_{+j} = \sum_{i=1}^C n_{ij} \quad (\text{F.2})$$

La précision globale est calculée avec :

$$OA = \frac{\sum_{i=1}^C n_{ii}}{NbP} \quad (\text{F.3})$$

La précision du producteur, pour la classe j est donnée par :

$$PA_j = \frac{n_{jj}}{n_{+j}} \quad (\text{F.4})$$

et pour la precision de l'utilisateur :

$$UA_i = \frac{n_{ii}}{n_{i+}} \quad (\text{F.5})$$

Une autre mesure qui peut être calculé sur la matrice de confusion est le coefficient Kappa définit par :

$$\hat{K} = \frac{NbP \sum_{i=1}^C n_{ii} - \sum_{i=1}^C n_{i+} n_{+i}}{NbP^2 - \sum_{i=1}^C n_{i+} n_{+i}} \quad (\text{F.6})$$

Ce coefficient est basé sur la différence entre l'accord réel dans la matrice de confusion (l'accord entre la classification et la référence comme est indiqué par la diagonale principale) et l'accord possible (indiquée par la ligne et la colonne de totales). Il mesure combien la classification concorde avec la référence.

Bibliographie

- [BEZDEK, 1973] BEZDEK, J. (1973). *Fuzzy mathematics in pattern classificatin*. PhD thesis, Cornell Univ., Ithaca, NY. 161
- [BEZDEK, 1980] BEZDEK, J. (1980). *IEEE Trans. Pattern Anal. Machine Intell.* **PAMI-2**, 1–8. 161, 162
- [BEZDEK, 1981] BEZDEK, J. (1981). *Pattern Recognition with Fuzzy Objective Function Algorithms*. Plenum, New York. 162
- [BLOCH, 1996] BLOCH, I. (1996). *IEEE Trans. on Systems Man and Cybernetics–Part A : Systems and Humans* **26**, 52–67. 55, 81
- [BOSCHETTI *et al.*, 2001] BOSCHETTI, L., FLASSE, S., TRIGG, S., and DE DIXMUDE, A. J. (2001). A multitemporal change-detection algorithm for the monitoring of burnt areas with SPOT-Vegetation data. In *Proc. of 1st Intl. Workshop on the Analysis of Multitemporal Remote Sensing Images, MultiTemp 2001*, pages 75–82, Trento, Italy. 26
- [BRIVIO *et al.*, 2001] BRIVIO, P. A., MAGGI, M., BINAGHI, E., GALLO, I., and GREGOIRE, J.-M. (2001). Exploiting spatial and temporal information for extracting burned areas from time series of SPOT-VGT data. In *Proc. of 1st Intl. Workshop on the Analysis of Multitemporal Remote Sensing Images, MultiTemp 2001*, pages 132–139, Trento, Italy. 26
- [BRUZZONE *et al.*, 2003] BRUZZONE, L., MARCONCINI, M., WEGMULLER, U., and WIESMANN, A. (2003). An Advanced System for Automatic Classification of Multitemporal SAR Images. In *Proc. of 2nd Intl. Workshop on the Analysis of Multitemporal Remote Sensing Images, MultiTemp 2003*, European Commission Joint Research Centre, Ispra, Italy. to appear. 61
- [BUJOR *et al.*, 2001] BUJOR, F. T., VALET, L., TROUVÉ, E., MAURIS, G., CLASSEAU, N., and RUDANT, J.-P. (2001). Data fusion approach for change detection in multi-

- temporal ERS-SAR images. In *Proc. of IEEE Geoscience and Remote Sensing Symposium IGARSS 2001*, volume 6, pages 2590–2592, Sydney, Australia. 90
- [CAVES and QUEGAN, 1994] CAVES, R. G. and QUEGAN, S. (1994). Segmentation based change detection in ERS-1 SAR images. In *Proc. of IEEE Geoscience and Remote Sensing Symposium IGARSS '94, 'Surface and Atmospheric Remote Sensing : Technologies, Data Analysis and Interpretation.'*, volume 4, pages 2149–2151, Pasadena, CA, USA. 21
- [CLASSEAU *et al.*, 1999] CLASSEAU, N., RUDANT, J., TREBOSEN, H., JEANNE, I., and GUILLOPE, P. (1999). Geographic data base enriching from ERS SAR scenes : Examples in French Guiana. In *Comm. on Earth Observation Satellites Conference*, Toulouse, France. 96
- [COLTUC *et al.*, 2000] COLTUC, D., TROUVÉ, E., BUJOR, F., CLASSEAU, N., and RUDANT, J.-P. (2000). Time-space filtering of multitemporal SAR images. In *Proc. of IEEE Geoscience and Remote Sensing Symposium IGARSS 2000*, volume 7, pages 2909–2911, Honolulu, HI, USA. 24
- [COPPIN *et al.*, 2001] COPPIN, P., JONCKHEERE, I., MUYS, B., and LAMBIN, E. (2001). Digital change detection methods in natural ecosystem monitoring : A review. In *Proc. of 1st Intl. Workshop on the Analysis of Multitemporal Remote Sensing Images, MultiTemp 2001*, pages 3–36, Trento, Italy. 19, 20, 21
- [COPPIN and BAUER, 1994] COPPIN, P. R. and BAUER, M. E. (1994). *IEEE Trans. on Geoscience and Remote Sensing* **32**, 918–927. 26
- [CURLANDER and MCDONOUGH, 1991] CURLANDER, J. C. and MCDONOUGH, R. N. (1991). *Synthetic aperture radar : systems and signal processing*. John Wiley & Sons, New York. 122
- [DELIGNON, 1993] DELIGNON, Y. (1993). *Etude statistique d'images radar de la surface de la mer*. PhD thesis, Université de Rennes 1. 129
- [DUBOIS *et al.*, 1999] DUBOIS, D., FOULLOY, L., GALICHET, S., and PRADE, H. (1999). *Performing approximate reasoning with words - In Computing with words in Information/Intelligent systems 1*, pages 24–49. Springer Verlag. 93
- [DUPONT, 1997] DUPONT, S. (1997). *Génération de modèles numériques de terrain par interférométrie ROS*. Thèse de doctorat, TU-0482, 156 pages, INRIA. 18
- [ENGESET and WEYDAHL, 1998] ENGESET, R. V. and WEYDAHL, D. J. (1998). *IEEE Trans. on Geoscience and Remote Sensing* **36**, 1879–1887. 22, 27

- [FLOREA, 2003] FLOREA, F. (2003). Fusion d'information par Machines à Vecteurs de Support. Rapport DEA, ESIA, Université de Savoie, Annecy, France. 169
- [FRANSSON *et al.*, 2002] FRANSSON, J. E. S., WALTER, F., BLENNOW, K., GUSTAVSSON, A., and ULANDER, L. M. H. (2002). *IEEE Trans. on Geoscience and Remote Sensing* **40**, 2170–2175. 24
- [FRIEDMAN *et al.*, 1999] FRIEDMAN, K. S., CLEMENTE-COLÓN, P., PICHEL, W. G., and LI, X. (1999). *Remote Sensing of Environment* **70**, 257–264. 22
- [FUNG, 1990] FUNG, T. (1990). *IEEE Trans. on Geoscience and Remote Sensing* **28**, 681–684. 26
- [GEOSCIENCE and REMOTE SENSING SOCIETY,] GEOSCIENCE, I. and REMOTE SENSING SOCIETY. Data Fusion Committee benchmark images. <http://www.dfc-grss.org/>. 34
- [GOODMAN, 1976] GOODMAN, J. (1976). *Journal Optical Society of America* **66**, 1145–1150. 128
- [GOPAL and WOODCOCK, 1996] GOPAL, S. and WOODCOCK, C. (1996). *IEEE Trans. on Geoscience and Remote Sensing* **34**, 398–404. 25
- [GROVER *et al.*, 1999] GROVER, K., QUEGAN, S., and DA COSTA FREITAS, C. (1999). *IEEE Trans. on Geoscience and Remote Sensing* **37**, 479–490. 26
- [HAVERKAMP and TSATSOULIS, 1999] HAVERKAMP, D. and TSATSOULIS, C. (1999). *IEEE Trans. on Geoscience and Remote Sensing* **37**, 1278–1291. 16
- [HAZEL, 2001] HAZEL, G. G. (2001). *IEEE Trans. on Geoscience and Remote Sensing* **39**, 553–561. 20
- [HOFFER and LEE, 1989] HOFFER, R. M. and LEE, K. S. (1989). Forest Change Classification Using Seasat And SIR-B Satellite SAR Data. In *Proc. of IEEE Geoscience and Remote Sensing Symposium IGARSS '89, 12th Canadian Symposium on Remote Sensing.*, volume 3, pages 1372–1375. 26
- [HOLECZ *et al.*, 2001] HOLECZ, F., DWYER, E., MONACO, S., SCHMID, B., FISHER, R., and FREI, U. (2001). Multi-temporal, multi-sensor SAR data for operational rice field mapping. In *Proc. of 1st Intl. Workshop on the Analysis of Multitemporal Remote Sensing Images, MultiTemp 2001*, pages 298–304, Trento, Italy. 16
- [INGLADA, 2003] INGLADA, J. (2003). Change Detection on SAR Images by using a Parametric Estimation of the Kullback-Leibler Divergence. In *Proc. of IEEE Geoscience*

- and Remote Sensing Symposium IGARSS 2003*, volume 6, pages 4104–4106, Toulouse, France. 25
- [JOACHIMS, 1998a] JOACHIMS, T. (1998a). Making large-scale SVM learning practical. In B. SCHOLKOPF, C. BURGESS, A. S., editor, *Advances in Kernel Methods – Support Vector Learning*, pages 169–185. MIT Press. 168
- [JOACHIMS, 1998b] JOACHIMS, T. (1998b). Text categorization with support vector machines : learning with many relevant features. In *Proc. 10th European Conference on Machine Learning ECML-98*, pages 137–142. 168
- [JOACHIMS, 1999] JOACHIMS, T. (1999). Transductive inference for text classification using support vector machines. In *Proc. 16th International Conference on Machine Learning*, pages 200–209. Morgan Kaufmann, San Francisco, CA. 168
- [JOACHIMS, 2000] JOACHIMS, T. (2000). Estimating the Generalization Performance of an SVM Efficiently. In *Proc. 17th International Conf. on Machine Learning*, pages 431–438. Morgan Kaufmann, San Francisco, CA. 168
- [KELLY *et al.*, 1988] KELLY, P., DERIN, H., and HARTT, K. (1988). *IEEE Trans. on Acoustics Speech and Signal Processing* **36**, 1628–1641. 129
- [KHODJA, 1997] KHODJA, L. (1997). *Contribution à la classification floue non supervisée*. PhD thesis, Université de Savoie. 161
- [KOSKINENA and HALLIKAINEN, 1997] KOSKINENA, J. and HALLIKAINEN, M. (1997). *Physics and Chemistry of The Earth* **22**, 285–289. 27
- [LAMBIN, 1995] LAMBIN, E. F. (1995). The role of remote sensing in models of deforestation processes. In *Proc. of IEEE Geoscience and Remote Sensing Symposium IGARSS '95, 'Quantitative Remote Sensing for Science and Applications'*, volume 2, pages 1542–1544, Florence, Italy. 26
- [LAUR, 1989] LAUR, H. (1989). *Analyse d'images radar en télédétection, discriminateurs radiométriques et texturaux*. PhD thesis, Université Paul Sabatier de Toulouse. 129
- [LEBERL, 1990] LEBERL, F. (1990). *Radargrammetric Image Processing*. Artech House, Norwood. 128
- [LEE *et al.*, 1994] LEE, J., JURKEVICH, I., DEWAELE, P., WAMBACQ, P., and OOSTERLINCK, A. (1994). *Remote Sensing Reviews* **8**, 313–340. 16
- [LOMBARDO and OLIVER, 1994] LOMBARDO, P. and OLIVER, C. J. (1994). *IEE Proc. Radar Sonar Navig* **141**, 196–204. 17, 23, 67

- [LOMBARDO and OLIVER, 2001] LOMBARDO, P. and OLIVER, C. J. (2001). *IEE Proc. Radar Sonar Navig* **148**, 200–210. [23](#), [25](#), [67](#)
- [LOMBARDO and PELLIZZERI, 2002] LOMBARDO, P. and PELLIZZERI, T. M. (2002). *IEEE Trans. on Geoscience and Remote Sensing* **40**, 853–870. [25](#)
- [MAÎTRE, 2001] MAÎTRE, H. (2001). *Traitement des Images de Radar à Synthèse d'Ouverture*. Hermès Science Publications, Paris. [13](#), [47](#), [113](#), [121](#)
- [MAURIS *et al.*, 1996] MAURIS, G., BENOIT, E., and FOULLOY, L. (1996). *Measurement* **17**, 235–249. [81](#)
- [NAGLER and ROTT, 2000] NAGLER, T. and ROTT, H. (2000). *IEEE Trans. on Geoscience and Remote Sensing* **38**, 754–765. [27](#)
- [NICOLAS and TUPIN, 2002] NICOLAS, J. and TUPIN, F. (2002). Gamma mixture modeled with “second kind statistics” : Application to SAR image processing. In *Proc. of IEEE Geoscience and Remote Sensing Symposium IGARSS 2002*, volume 4, pages 2489–2491, Toronto, Canada. [62](#)
- [NICOLAS, 2002] NICOLAS, J.-M. (2002). *Traitement du Signal* **19**, 139–167. [58](#), [60](#), [66](#)
- [OHKURA, 1998] OHKURA, H. (1998). *Advances in Space Research* **21**, 485–492. [27](#)
- [OHKURA *et al.*, 1997] OHKURA, H., JITSUFUCHI, T., MATSUMOTO, T., and FUJINAWA, Y. (1997). *Advances in Space Research* **19**, 1429–1436. [27](#)
- [OLIVER, 2000] OLIVER, C. J. (2000). *IEEE Trans. on Geoscience and Remote Sensing* **38**, 1095–1104. [17](#)
- [OLIVER and QUEGAN, 1998] OLIVER, C. J. and QUEGAN, S. (1998). *Understanding Synthetic Aperture Radar Images*. Artech House Inc. , Norwood, MA. [17](#), [42](#)
- [PAQUERAULT, 1998] PAQUERAULT, S. (1998). *Restitution du relief à partir d'images radar par radarclinométrie*. Thèse de doctorat, ENST 98 E 007, 196 pages, ENST. [18](#), [127](#)
- [POHL and GENDEREN, 1998] POHL, C. and GENDEREN, J. V. (1998). *International Journal on Remote Sensing* **19**, 823–854. [73](#)
- [PROISY *et al.*, 2000] PROISY, C., MOUGIN, E., DUFRÊNE, E., and DANTEC, V. L. (2000). *IEEE Trans. on Geoscience and Remote Sensing* **38**, 540–552. [27](#)
- [QUEGAN *et al.*, 2000] QUEGAN, S., TOAN, T. L., YU, J. J., RIBBES, F., and FLOURY, N. (2000). *IEEE Trans. on Geoscience and Remote Sensing* **38**, 741–753. [16](#), [23](#)

- [QUEGAN *et al.*, 1988] QUEGAN, S., YANASSE, C., BLACK, S., and DANSON, M. (1988). Change Detection In Agrisar Images. In *Proc. of IEEE Geoscience and Remote Sensing Symposium IGARSS '88, 'Remote Sensing : Moving Toward the 21st Century'*, volume 2, pages 1139–1140. 26
- [RIDD and LIU, 1998] RIDD, M. K. and LIU, J. (1998). *Remote Sensing of Environment* **63**, 95–100. 23, 26
- [RIGNOT and CHELLAPPA, 1992] RIGNOT, E. and CHELLAPPA, R. (1992). A Bayes classifier for change detection in synthetic aperture radar imagery. In *Proc. of IEEE International Conference on Acoustics, Speech, and Signal Processing ICASSP-92*, volume 3, pages 25–28, San Francisco, CA, USA. 25
- [RIGNOT and VAN ZYL, 1993] RIGNOT, E. J. M. and VAN ZYL, J. J. (1993). *IEEE Trans. on Geoscience and Remote Sensing* **31**, 896–906. 21, 22
- [ROGAN *et al.*, 2002] ROGAN, J., FRANKLIN, J., and ROBERTS, D. A. (2002). *Remote Sensing of Environment* **80**, 143–156. 26
- [ROSIN and HERVÁS, 2001] ROSIN, P. L. and HERVÁS, J. (2001). Image thresholding for landslide detection by genetic programming. In *Proc. of 1st Intl. Workshop on the Analysis of Multitemporal Remote Sensing Images, MultiTemp 2001*, pages 67–74, Trento, Italy. 26
- [SCHÖLKOPF *et al.*, 1999] SCHÖLKOPF, B., SMOLA, A. J., and MÜLLER, K.-R. (1999). Kernel principal component analysis. In SCHÖLKOPF, B., BURGESS, C., and SMOLA, A., editors, *Advances in Kernel Methods - Support Vector Learning*, pages 327–352. MIT Press. 77
- [SHAKER and HUSSIN, 1995] SHAKER, S. R. and HUSSIN, Y. A. (1995). A comparison between optical and microwave satellite data in monitoring tropical land use changes. In *Proc. of IEEE Geoscience and Remote Sensing Symposium IGARSS '95, 'Quantitative Remote Sensing for Science and Applications'*, volume 2, pages 1532–1534, Florence, Italy. 26
- [SINGH, 1989] SINGH, A. (1989). *International Journal on Remote Sensing* **10**, 989–1003. 19, 20, 21, 23
- [SOLBERG, 1999] SOLBERG, A. H. S. (1999). *IEEE Trans. on Geoscience and Remote Sensing* **37**, 1234–1243. 18
- [STANCU *et al.*, 2002] STANCU, S., BUJOR, F. T., TROUVÉ, E., MAURIS, G., BOLON, P., and RUDANT, J.-P. (2002). Improving Feature Extraction in Satellite SAR Images

- by an Interactive Fuzzy Fusion of Multi-Temporal Data. In *Proc. of IEEE Geoscience and Remote Sensing Symposium IGARSS 2002*, volume I, pages 75–78, Toronto, Canada. 17
- [TOUZI *et al.*, 1988] TOUZI, R., LOPES, A., and BOUSQUET, P. (1988). *IEEE Trans. on Geoscience and Remote Sensing* **26**, 764–773. 47, 48
- [TOWNSHEND *et al.*, 1992] TOWNSHEND, J. R. G., JUSTICE, C. O., GURNEY, C., and McMANUS, J. (1992). *IEEE Trans. on Geoscience and Remote Sensing* **30**, 1054–1060. 25
- [TRÉBOSSON *et al.*, 2000] TRÉBOSSON, H., RUDANT, J. P., FRUNEAU, B., and CLASSEAU, N. (2000). Contribution of SAR imagery for mapping coastal's areas : examples of sedimentationnal and erosionnal zones in French Guiana and Mauritania. In *Sixth International Conference on Remote Sensing for Marine and Coastal Environments*, volume 2, pages 398–405, Charleston, South Carolina, USA. 16
- [TROUVÉ, 1996] TROUVÉ, E. (1996). *Imagerie interférentielle en radar à ouverture synthétique*. Thèse de doctorat, ENST 96 E 014, 261 pages, ENST. 121
- [TROUVÉ *et al.*, 2003] TROUVÉ, E., CHAMBENOIT, Y., CLASSEAU, N., and BOLON, P. (2003). *IEEE Trans. on Geoscience and Remote Sensing* **41**, 2519–2530. 16
- [UMLV–98, 1998] UMLV–98 (1998). Evaluation du potentiel cartographique des images satellitaires radar ERS-1. Phase II : Des prototypes à la cartographie complète de la Guyane française. Technical Report 85276/STAT/SCB.GE/OP4, IGN Espace, Université Paris VI. 15, 31
- [VACCARO *et al.*, 2000] VACCARO, R., SMITS, P., and DELLEPIANE, S. (2000). *IEEE Trans. on Geoscience and Remote Sensing* **38**, 1212–1223. 17
- [VALET, 2001] VALET, L. (2001). *Un système flou de fusion coopérative : application au traitement d'images naturelles*. Thèse de doctorat, LAMII, 261 pages, Université de Savoie. 114
- [VALET *et al.*, 2001] VALET, L., MAURIS, G., BOLON, P., and KESKES, N. (2001). *IEEE Trans. on Instrumentation and Measurement* **50**, 1014–1018. 78
- [VAPNIK, 1979] VAPNIK, V. (1979). *Estimation of Dependences Based on Empirical Data [in Russian]*. Nauka, Moscow. 165
- [VAPNIK, 1995] VAPNIK, V. (1995). *The Nature of Statistical Learning Theory*. Springer, N.Y. 168

- [VAPNIK, 1998] VAPNIK, V. (1998). *Statistical Learning Theory*. Wiley, New-York. 77
- [VILLASENOR *et al.*, 1993] VILLASENOR, J. D., FATLAND, D. R., and HINZMAN, L. D. (1993). *IEEE Trans. on Geoscience and Remote Sensing* **31**, 227–236. 27
- [WALD, 1999] WALD, L. (1999). *IEEE Trans. on Geoscience and Remote Sensing* **37**, 1190–1193. 71, 73
- [WEYDAHL, 1996] WEYDAHL, D. J. (1996). Flood monitoring in Norway using ERS-1 SAR images. In *Proc. of IEEE Geoscience and Remote Sensing Symposium IGARSS '96, 'Remote Sensing for a Sustainable Future.'*, volume 1, pages 151–153, Lincoln, Nebraska, USA. 16, 25, 27
- [WEYDAHL, 2001] WEYDAHL, D. J. (2001). *IEEE Trans. on Geoscience and Remote Sensing* **39**, 2029–2039. 27
- [WHITE and OLIVER, 1990] WHITE, R. G. and OLIVER, C. J. (1990). Change detection in SAR imagery. In *Record of the IEEE 1990 International Radar Conference*, pages 217–222. 21
- [WOOD *et al.*, 1988] WOOD, J. W., WHITE, R. G., and OLIVER, C. J. (1988). Distortion free SAR imagery and change detection. In *Proc. of the 1988 IEEE National Radar Conference*, pages 95–99. 21
- [YAMAMOTO *et al.*, 2001] YAMAMOTO, T., HANAIZUMI, H., and CHINO, S. (2001). *IEEE Trans. on Geoscience and Remote Sensing* **39**, 976–985. 21
- [ZADEH, 1965] ZADEH, L. A. (1965). *Information and Control* **8**, 338–353. 78, 93
- [ZADEH, 1971] ZADEH, L. A. (1971). *Information Sciences* **3**, 177–200. 79, 92

Publications de l'auteur

Revue internationale avec comité de lecture

F.T. Bujor, E. Trouvé, L. Valet, Ph. Bolon, J.-M. Nicolas, J.-P. Rudant, V. Buzuloiu, *Feature Detection in Multi-temporal SAR Images by an Interactive Fuzzy Fusion Method*. Soumission Janvier 2004 pour Remote Sensing of Environment, manuscrit no. RSE-D-04-00493.

F. Bujor, E. Trouvé, L. Valet, J.-M. Nicolas, J.-P. Rudant, *Application of Log-cumulants to the Detection of Spatio-temporal Discontinuities in Multi-temporal SAR Images*. Accepté pour publication en IEEE Transactions on Geoscience and Remote Sensing.

Communications dans des congrès internationaux avec comité de lecture et actes

F.T. Bujor, J.-M. Nicolas, E. Trouvé, L. Valet, Ph. Bolon, J.-P. Rudant, *Feature Detection in Multi-temporal SAR images*, In Proc. of 2nd Intl. Workshop on the Analysis of Multitemporal Remote Sensing Images, MultiTemp 2003, European Commission Joint Research Centre, Ispra, Italie, 16-18 Juillet 2003 .

F.T. Bujor, J.-M. Nicolas, E. Trouvé, J.-P. Rudant, *Application of Log-cumulants to Change Detection in Multi-temporal SAR Images*, In Proc. of IEEE Geoscience and Remote Sensing Symposium IGARSS 2003, volume 2, pp. 1386-1388, Toulouse, France, Juillet 2003.

L. Valet, **F. Bujor**, G. Mauris, E. Trouvé, Ph. Bolon, *Multi-temporal SAR Image Analysis by a 3D Graphic Tool-Based Fuzzy Fusion*, In Proc. of 6th Conference on Information Fusion FUSION 2003, pp.1478-1483, Cairns, Queensland, Australia, Juillet 2003.

F.T. Bujor, L. Valet, E. Trouvé, G. Mauris, Ph. Bolon, *An Interactive Fuzzy Fusion System Applied to Change Detection in SAR Images*, In Proc. of the 2002 IEEE International Conference on Fuzzy Systems, 2002. FUZZ-IEEE'02, volume 2, pp.932-937, Honolulu, HI, SUA, Mai 2002.

S. Stancu, **F.T. Bujor**, E. Trouvé, G. Mauris, Ph. Bolon, J.-P. Rudant, *Improving Feature Extraction in Satellite SAR Images by an Interactive Fuzzy Fusion of Multi-temporal Data*, In Proc. of IEEE Geoscience and Remote Sensing Symposium IGARSS 2002, volume I, pp. 75-78, Toronto, Canada, Juin 2002.

E. Trouvé, M. Ciuc, **F.T. Bujor**, Ph. Bolon, N. Classeau, J. P. Rudant, DA. Coltuc. *Performance assessment in multi-temporal SAR image filtering*, In Proc. of 1st Intl. Workshop on the Analysis of Multitemporal Remote Sensing Images, MultiTemp 2001, pp. 198-205, Trento, Italie, 13-14 Septembre 2001.

F.T. Bujor, L. Valet, E. Trouvé, G. Mauris, N. Classeau, J.-P. Rudant, *Data Fusion Approach for Change Detection in Multi-temporal ERS-SAR Images*, Proceedings of IEEE Geoscience and Remote Sensing Symposium IGARSS 2001, volume 6, pp. 2590-2592, Sydney, Australia, Juillet 2001.

E. Trouvé, D. Coltuc, **F. Bujor**, N. Classeau, J.-P. Rudant, *Time-space Filtering of Multi-temporal SAR Images*, Proceedings of IGARRS 2000, volume 7, pp.2909-2911, Honolulu, Hawaii, SUA, Juillet 2000.

Communications dans des congrès nationaux avec comité de lecture et actes

F.T. Bujor, L. Valet, E. Trouvé, J.-M. Nicolas, G. Mauris, Ph. Bolon, *Fusion floue d'attributs pour la détection de changements dans les images RSO*, Le 19ème Colloque GRETSI sur le Traitement du Signal et des Images, GRETSI'03, volume 3, pp.276-279, Paris, France, 8-10 September 2003.

F.T. Bujor, L. Valet, E. Trouvé, G. Mauris, Ph. Bolon, *Détection de changements dans les images RSO par fusion floue interactive d'informations*, Rencontres francophones sur la logique floue et ses applications, LFA 2001, pp.171-178, Mons, Belgique, 26-27 Novembre 2001.