



N° d'ordre : **xxx/2017**

THESE UNIQUE

Pour l'obtention du grade de

Docteur de l'Institut National Polytechnique Félix Houphouët Boigny de Yamoussoukro

Domaine

SCIENCES INFORMATIQUES

Spécialité

Traitement de l'image

Présentée par

ATIAMPO Kodjo Armand

SUJET

UN NOUVEAU MODELE MARKOVIAN POUR LA DETECTION DES CHANGEMENTS DANS LES IMAGES A TRES HAUTE RESOLUTION SPATIALE

Soutenu publiquement le 22 Décembre 2017 devant le Jury composé de :

ZOUEU T. Jérémie	Professeur Titulaire	Institut National Polytechnique Félix Houphouët Boigny de Yamoussoukro, Côte d'Ivoire	Président
LOUM L. Georges	Maître de Conférences	Institut National Polytechnique Félix Houphouët Boigny de Yamoussoukro, Côte d'Ivoire	Directeur
NIANG Oumar	Maître de Conférences	Ecole Polytechnique de Thiès, Sénégal	Rapporteur
MONSAN Vincent	Maître de Conférences	Université Félix Houphouët Boigny, Abidjan Côte d'Ivoire	Rapporteur
AKA Boko	Professeur Titulaire	Université Nangui-Abrogoua, Abidjan, Côte d'Ivoire	Examineur

A la mémoire de mon défunt père

Remerciements

La thèse de doctorat représente un travail non solitaire qui s'inscrit dans la durée. Je n'aurais jamais pu réaliser ce travail doctoral sans le soutien de personnes dont la générosité, la bonne humeur et l'intérêt manifestés à l'égard de ma recherche m'ont permis de progresser dans cette phase délicate de « l'apprenti chercheur ». Ce sont toutes ces personnes que j'aimerais mettre en avant dans ces remerciements.

En premier lieu, je tiens à remercier mon directeur de thèse, le Docteur Maître de Conférences LOUM Georges L., pour la confiance qu'il m'a accordée en acceptant d'encadrer ce travail et pour toutes les heures qu'il a consacrées à diriger cette recherche. J'aimerais également lui dire merci pour sa grande disponibilité et son respect sans faille des délais serrés de relectures des documents que je lui ai adressés.

Ce travail n'aurait pas été possible sans le soutien de l'école doctorale de l'Institut National Polytechnique Félix Houphouët-Boigny en particulier de son directeur, le Professeur YAO Benjamin et du Directeur de l'UMRI 78 le Professeur ZOUEU Jérémie qui contribuent par leurs actions à la promotion de la recherche fondamentale et appliquée en Côte d'Ivoire. Je voudrais également lui dire un grand merci pour avoir accepté de présider le jury de cette thèse.

Je souhaiterais également exprimer toute ma gratitude au conseil scientifique et au corps professoral du LARIT en particulier au Professeur BABRI Michel pour la qualité de l'encadrement des travaux de thèse et de master.

Mes remerciements vont également au Docteur Maître de Conférences NIANG Oumar de l'Ecole Polytechnique de Thiès et au Docteur Maître de conférences MONSAN Vincent de l'UFR Mathématique et Informatique de l'Université Félix Houphouët-Boigny qui malgré leur charge de travail importante, ont accepté de rapporter cette thèse.

Mes vifs remerciements vont au Professeur AKA Boko de l'Université Nangui-Abrogoua pour avoir accepté la lourde tâche d'en être l'examineur et pour sa participation au jury de cette thèse.

Ce travail n'aurait pu être mené à bien sans la disponibilité et l'accueil chaleureux que m'ont témoignés mes aînés : les Docteurs TCHIMOU N'Takpe, N'GUESSAN Behou Gerard, ANOH Georges, ADEPO Joel et ACHIEPO Odilon.

Mes remerciements vont également aux membres de l'équipe Signal, Image et Vision du LARIT : OUATTARA Nouho et PANDRY Koffi Ghislain qui m'ont fourni une aide précieuse dans l'avancement de mes travaux de recherche.

Au terme de ce parcours, je remercie enfin ceux et celles qui me sont chers et que j'ai quelque peu délaissés ces derniers mois pour achever cette thèse. Leurs attentions et encouragements m'ont accompagné tout au long de ces années. Je suis redevable à ma mère, mon épouse BOKO José, mes frères Charles, Raymond et Guy-Roger pour leur soutien moral et leur confiance indéfectible dans mes choix. Enfin, j'ai une pensée toute particulière pour mon défunt père qui m'a donné le goût pour la recherche scientifique.

Résumé

Détecter automatiquement les changements entre une paire ou une séquence d'images, soulève un problème majeur qui est celui de l'interprétation de la notion de zone changée. Elle se traduit par la construction d'un masque de changement qui discrimine les zones changées des zones non changées. Cette interprétation ne se limite pas uniquement à identifier les différences d'intensité des pixels entre deux images mais consiste à trouver une interprétation sémantique en fonction de l'application désirée. Cela a pour conséquence le développement de méthodes adaptées à la nature de l'application désirée. Une des applications les plus importantes est le suivi de l'occupation et de l'utilisation des sols qui passe par la détection des changements survenus sur une même zone géographique à des périodes différentes. Ce suivi permet alors de connaître l'impact de l'anthropisation sur l'environnement. L'un des principaux outils utilisés est l'analyse des images issues de la télédétection spatiale. Jusqu'au début de ce millénaire, les imageurs satellites fournissaient des images représentant des grandes zones homogènes et leur utilisation dans la détection des changements se limitait à analyser les changements abrupts comme le passage d'une classe d'occupation à une autre. De plus, cette détection des changements s'effectuait à l'aide d'images provenant de capteurs homogènes. Les changements fins qui interviennent à l'échelle locale n'étaient pas pris en compte. L'avènement au début des années 2000 des satellites de télédétection à Très Haute Résolution Spatiale a permis de s'intéresser à ce type de changements qui implique la prise en compte de l'organisation spatiale des objets présents dans les images de la zone. De plus, ces capteurs qui connaissent un développement croissant fournissent à la fois des images de type panchromatique, multispectral, voire hyperspectral. De l'autre côté, les radars imageurs sont devenus populaires et sont complémentaires des imageurs optiques. La diversité de la nature des images disponibles a pour conséquence le développement de méthodes adaptées à l'hétérogénéité des capteurs. L'objectif de cette thèse est de proposer une nouvelle méthode de détection des changements capables de les détecter aussi bien sur une paire d'images homogènes qu'hétérogènes. Pour ce faire, la nouvelle approche s'est fondée sur les paradigmes de l'analyse d'images par l'approche objet. Elle se décompose en deux étapes à savoir, une première phase d'extraction des objets par un algorithme de segmentation en superpixels et une deuxième phase qui est la construction d'une nouvelle mesure de dépendance à l'aide des copules. La construction de la mesure de la dépendance est réalisée par la projection des images dans un espace de descripteurs de textures à 9 dimensions. Cet espace est construit à partir des moments orthogonaux discrets de

Tchebychev invariants par translation, rotation et facteur d'échelle ou TRE invariants. Dans chacune des dimensions, une mesure de dépendance est construite par caractérisation des dépendances à l'aide d'un dictionnaire de copules. La mesure globale est obtenue par combinaison linéaire des mesures de dépendances dans chacune des 9 dimensions. La matrice des dépendances est ensuite soumise à un classifieur markovien. Celui-ci, utilise les chaînes de Markov couple et modélise la dépendance spatiale à l'aide des copules.

Ce nouveau modèle présente trois intérêts. Tout d'abord, la segmentation par superpixels permet une extraction automatique des objets et pallie ainsi une limitation de l'analyse d'image à THRS qui est celle de la présence d'un photo-interprète. Le deuxième intérêt réside dans l'utilisation des moments orthogonaux discrets de Tchebychev TRE invariants. Ces polynômes permettent de décrire les textures indépendamment de toute transformation géométrique subie dans l'image. Cela a pour conséquence une réduction du volume de l'information nécessaire pour caractériser les textures contrairement à une analyse multirésolution. Le troisième intérêt est la construction d'une mesure basée sur un modèle de dépendance indépendant de la distribution statistique des distributions des paramètres.

Les premières expériences menées sur des images homogènes et hétérogènes de type optique et radar montrent des résultats encourageants par comparaison aux mesures de similarité classiques que sont le coefficient de corrélation linéaire et l'information mutuelle.

Mots clés : Détection de changements, chaînes de Markov couple, Moments orthogonaux discrets de Tchebychev, Superpixels, images à Très Haute Résolution Spatiale.

Abstract

Automatically detecting changes between a pair or a sequence of images raises a major problem, which is the interpretation of the changed area concept. This interpretation is not limited only to identifying the differences in intensity of the pixels between two images but consists in finding a semantic interpretation according to the desired application by the construction of a change mask which discriminates the changed areas and unchanged areas. This results in the development of methods adapted to the nature of the desired application. One of the most important applications is the monitoring of land use and land use, which involves detecting changes in the same geographical area at different times. This monitoring then makes it possible to know the impact of anthropization on the environment. One of the main tools used is the analysis of images from remote sensing. Until the beginning of this millennium, remote sensing satellites were providing images representing large homogeneous areas and their use in detecting changes was limited to analyzing abrupt changes such as switching from one land cover class to another. Moreover, this detection of the changes was carried out using homogeneous images. Fine changes at the local level were not taken into account. The advent of remote sensing satellites with very high spatial resolution in the early 2000s made it possible to take an interest in this type of change, which implies taking into account the spatial organization of the objects present in the images of the zone. In addition, these sensors, which know an accelerate developmmt, provide both panchromatic, multispectral and even hyperspectral images. On the other hand, imaging radars have become popular and complementary to optical satellites. The diversity of the nature of the images available results in the development of methods adapted to the heterogeneity of the sensors. The aim of this thesis is to propose a new method for detecting changes capable of detecting them both on a pair of homogeneous and heterogeneous images. To do this, the new approach is based on the paradigms of the analysis of images by the object-oriented approach. she decomposes in two steps, namely, a first phase of extraction of the objects by a superpixel segmentation algorithm and a second phase which is the construction of a new dependency measure using the copulas. The construction of the measure of the dependence is carried out by the projection of the images in a space of 9-dimensional textures descriptors. This space is constructed from the discrete orthogonal moments of Tchebyshev invariant by translation, rotation and scaling factor. In each dimension, a dependence measure is constructed by characterizing the dependencies using a copula dictionary. The overall measure is obtained by linear combination of the dependence

measure in each of the ten dimensions. The dependency matrix is then subjected to a Markov classifier. This one, uses the pairwise Markov chains and models the spatial dependence using the copulas ;

This new model has three interests. Firstly, segmentation by superpixels allows automatic extraction of objects and thus compensates for a limitation of the Very High Spatial Resolution image analysis which is that of the presence of a photo-interpreter. The second interest lies in the use of TRS invariants of Tchebychev discrete orthogonal moments. These moments make it possible to describe the textures independently of any geometric transformation undergone in the image. This results in a reduction in the amount of information needed to characterize the textures as opposed to a multiresolution analysis. The third interest is the construction of a measure based on a dependence model independent of the statistical distribution of parameter distributions.

The first experiments carried out on homogeneous and heterogeneous images of the optical and radar type show encouraging results compared to the conventional similarity measurements which are the coefficient of linear correlation and the mutual information.

Keywords: Change detection, Pairwise Markov chains, Tchebychev discrete orthogonal moments Chebyshev, Superpixels, Very High Spatial Resolution images

Table des matières

Remerciements	ii
Résumé	iv
Abstract	vi
Table des matières	viii
Liste des figures	xi
Liste des tableaux	xiv
Abréviations	xv
Introduction	1
Chapitre 1 Position du problème	5
1.1 Introduction	6
1.2. Imagerie satellitaire à très haute résolution spatiale.....	8
1.2.1 Imageurs optiques.....	9
1.2.1.1 Caractéristiques des capteurs optiques	11
1.2.1.2 Satellites optiques.....	14
1.2.2 Radars imageurs	20
1.2.2.1. Caractéristiques des radars imageurs.....	20
1.2.2.2. TerraSAR-X	23
1.3. Enjeux de la détection des changements dans les images à THRS	24
1.3.1 Enjeux de la détection de changement	24
1.3.2. Définition de l'objet géographique et représentation numérique	26
1.3.3. Détection des changements dans le cas des images THRS	27
1.4. Conclusion.....	28
Chapitre 2 Etat de l'art des méthodes de détection des changements	30
2.1. Introduction	31
2.2. Détection des changements dans les images optiques	32
2.3. Détection des changements dans les images radars	35
2.4. Détection des changements à base de mesure de similarité	37
2.4.1. Coefficient de corrélation linéaire.....	39
2.4.2. Information mutuelle.....	41
2.4.3. Divergence de Kullback-Liebler	43
2.5. Conclusion.....	44
Chapitre 3 Extraction des primitives de texture dans les images de télédétection	46
3.1. Introduction	47

3.2. Méthodes statistiques	49
3.2.1. Matrice de cooccurrence des niveaux de gris	49
3.2.2. Variogrammes	51
3.3. Méthodes basées sur un filtrage	53
3.3.1. Analyse de la texture par transformée de Fourier.....	53
3.3.2. Analyse de la texture par filtrage de Gabor.....	55
3.3.3. Analyse de la texture par transformée en ondelettes	57
3.4. Description des textures à l'aide des moments orthogonaux discrets de Tchebychev.....	59
3.4.1. Moments locaux de Tchebychev	60
3.4.2. Moments locaux de Tchebychev TRE invariants.....	64
3.5. Conclusion.....	69
Chapitre 4 Nouvelle mesure de similarité pour la détection des changements dans les images à THRS	70
4.1. Introduction	71
4.2. Segmentation en superpixels	71
4.2.1. Décomposition en superpixels.....	72
4.2.2. L'algorithme SLIC	73
4.3. Estimation de la mesure de similarité	74
4.3.1. Modélisation statistique des distributions de probabilité marginales	74
4.3.1.1. Images optiques	75
4.3.1.2. Les images radar à synthèse d'ouverture (RSO)	76
4.3.2. Distribution jointe.....	77
4.3.2.1. Zones homogènes	77
4.3.2.2. Zone hétérogène	78
4.3.2.3. Nouvelle mesure de similarité	79
4.4. Estimation des paramètres.....	82
4.4.1. Sélection de la meilleure copule.....	82
4.4.2. Estimation des paramètres du mélange des densités	85
4.5. Analyse des résultats sur des données de synthèse	87
4.6. Conclusion.....	90
Chapitre 5 Estimation non paramétrique des chaînes de Markov couple.....	92
5.1. Introduction	93
5.2. Rappel sur les chaînes de Markov couple avec copules.....	94
5.2.1. Rappels préliminaires sur les chaînes de Markov couple.....	94
5.2.2. Définition des chaînes de Markov couple avec copule	97
5.3. Estimation de la densité de la copule à l'aide des polynômes orthogonaux	100
5.3.1. Rappel sur les copules	100
5.3.2. Estimation de la densité de la copule à l'aide des polynômes orthogonaux.....	103
5.4. Restauration MPM des chaînes de Markov couple	106

5.5. Estimation des paramètres des chaînes de Markov couple	107
5.6. Analyse et évaluation des résultats sur des images de synthèse	109
5.7. Analyse et évaluation des résultats sur des images réelles.....	114
5.7.1. Cas de deux images acquises par le même capteur	115
5.7.2. Cas de deux images acquises par des capteurs optiques différents	119
5.7.3. Cas de deux capteurs hétérogènes.....	121
5.8. Conclusion.....	125
Conclusion et perspectives.....	126
Liste des publications de l'auteur	127
ANNEXES.....	129
ANNEXE A : Estimation des moments de Tchebychev TRE invariants.....	130
ANNEXE B : Rappel sur les copules bivariées.....	133
Bibliographie.....	136

Liste des figures

1. 1	Impact des changements d'occupation et d'utilisation des sols occurring à une échelle locale sur une échelle globale (Source : [Lecerf 2010])	7
1. 2	Spectre électromagnétique (source : www.livementor.com).	10
1. 3	Sensibilité spectrale du capteur QuickBird	11
1. 4	Réponse spectrale du capteur panchromatique du satellite WorldView-1. (Source : [EL-Mezouar 2012])	11
1. 5	Réponse spectrale du capteur MS du satellite WorldView-2. (Source : [EL-Mezouar 2012])	12
1. 6	Image multispectrale en vraies couleurs du lion blanc du zoo de Whipsnade fournie par Pleiades en 2015 (Résolution 0.7m) (source @ CNES)	13
1. 7	Image SOPT multispectrale de la ville de Naples en fausses couleurs (Résolution 5m)	13
1. 8	Image de montagne dans la vallée de la mort (Nevada Californie) acquise par le capteur Hyperion en vraie couleur, Rouge=calcite, Jaune=dolomite, Violet=silice, Cyan=zéolites.	14
1. 9	Satellite QuickBird (Image copyright © DigitalGlobe)	15
1. 10	Vue d'artiste du satellite IKONOS-2 (Image copyright © GeoEye)	16
1. 11	Image du satellite GeoEye-1 (Source © DigitalGlobe)	18
1. 12	Image du satellite WorldView-2 (source © DigitalGlobe)	19
1. 13	Satellite Pléiade (Source © CNES)	20
1. 14	Image en négatif de la localité de Tienko prise par le radar ERS-1 prise en 1992 (Source : [Koffi et al. 2014])	21
1. 15	Principe du radar à synthèse d'ouverture(RSO) (Source : Wikipédia)	22
1. 16	Vue d'artiste du satellite TerraSAR-X (Source @ AIRBUS Defence & Space)	23
2. 1	Modèle de détections des changements à base d'analyse par fenêtres (source : [Prendes 2015])	38
2. 2	Image présentant une zone de prairie changée (a) texture de prairie (b) texture de forêt (c) histogramme joint	40
2. 3	Images d'une zone inchangée présentant deux objets distincts (a)Image optique présentant 2 objets (b) Image radar correspondante (c) histogramme joint	40
2. 4	Matrice de corrélation linéaire des deux images précédentes	41
2. 5	Matrice IM des deux images optiques et radar d'une même zone	43
3. 1	Images optiques THRS de taille 512×512 pixels présentant des zones texturées (a) cacaoyère en forêt (b) Cacaoyère en rang	46

3. 2	Exemple de matrices de cooccurrence de niveaux de gris. (a) texture uniforme (b) texture aléatoire (Paramètres de déplacement $(dx, dy)=(2,0)$, $\theta=0^\circ$)	50
3. 3	Exemples de semi-variogrammes – ligne pointillée = variogramme expérimental – ligne pleine = variogramme théorique estimée par modèle exponentiel (Source : [Regniers 2014])	51
3. 4	Spectre d’amplitude et de phase de la transformée de Fourier des images de textures (a) Cacaoyère en rang (b) Cacaoyère en forêt	53
3. 5	Transformée de Gabor selon deux orientations et deux échelles des deux zones texturées (a) Cacaoyère en rang (b) Cacaoyère en forêt	55
3. 6	Transformée en ondelettes de Daubechies à 2 niveaux de décompositions. (a) Image originale (b) Organisation des différents niveaux de décomposition (c) Résultat de la décomposition	57
3. 7	Différentes étapes de la construction de la matrice de texture selon les moments discrets orthogonaux locaux de Tchebychev proposé par Munkundan	59
3. 8	Polynômes de Tchebychev pour $n=0, 1, 2, 3,4$	60
3. 9	Représentation spatiale des noyaux de Tchebychev pour $N=6$	61
3. 10	Représentation du module du spectre des noyaux de Tchebychev pour $N=6$	61
3. 11	Processus de construction du vecteur des descripteurs	62
3. 12	Images binaires transformées par Translation rotation et facteur d'échelle	66
3. 13	Image d'une zone péri-urbaine acquise par IKONOS	67
3. 14	Matrice des attributs de textures extraits à partir des moments locaux de Tchebychev	67
4. 1	Segmentation en superpixels selon l’algorithme SLIC en 512 superpixels. (a) Décomposition de l’image référence (b) Décomposition de l’image changement	71
4. 2	Zone homogène capturée par deux capteurs différents (a) Senseur RSO (b) Senseur optique (Source : Prendes 2015])	76
4. 3	Histogramme joint et représentation de la courbe d'évolution des paramètres (a) histogramme joint (b) Courbe des paramètres	77
4. 4	Image de synthèse (a) Senseur optique (b) image radar (c) masque de changement modèle vérité terrain (source : [Prendes 2015])	87
4. 5	Masque de changement (a) Coefficient de corrélation (b) Information mutuelle (c) Notre approche	87
4. 6	Courbe ROC pour les images de synthèse	88
4. 7	Nouvel algorithme de détection des changements	90
5. 1	Graphe d'indépendance conditionnelle non-orienté d'une chaîne de Markov	93
5. 2	Parcours de Hilbert-Péano pour une image de taille 4x4 pixels	94
5. 3	Graphe de dépendance conditionnelle non orienté d'une chaîne de Markov couple	95

5. 4	Segmentation semi supervisée d'une chaine de Markov couple simulée ;(a) Chaine de Markov couple, (b) Version bruitée, (c) Estimation par les vrais paramètres, (d) CMCo-SAC, (e) CMC-BI, (f) CMCo-CNP	109
5. 5	Image de synthèse originale et bruitée ainsi que les versions obtenues après segmentation par chaines de Markov Couple	111
5. 6	Image Nazca et sa version bruitée	111
5. 7	Image Zèbre et sa version bruitée	112
5. 8	Résultats de la segmentation par différents algorithmes de chaines de Markov de l'image Nazca et Zèbre	112
5. 9	Images tests acquises par le satellite QuickBird (a) Avril 2004 (b) Juin 2005 (c) Vérité terrain (Source : [Wu et al. 2012])	115
5. 10	Mesures de similarités pour différents algorithmes (a) Coefficient de corrélation linéaire (b) Information mutuelle (c) Notre modèle	116
5. 11	Courbe ROC pour l'évaluation des performances de différents algorithmes	117
5. 12	Images tests acquises par les satellites Pleiades et Geo Eye (a) Pléiades - Mai 2012 (b) GeoEye 1 - Juin 2013 (c) Vérité terrain (Source : [Prendes 2015])	118
5. 13	Mesures de similarités pour différents algorithmes (a) Coefficient de corrélation linéaire (b) Information mutuelle (c) Notre modèle	119
5. 14	Courbe ROC pour l'évaluation des performances des différents algorithmes	120
5. 15	Images tests acquises par les satellites Geo Eye et TerraSAR-X (a) Geo Eye – Dec. 2006 (b) TerraSAR-X – Jul. 2007 (c) Vérité terrain (Source : [Prendes 2015])	121
5. 16	Mesures de similarités pour différents algorithmes (a) Coefficient de corrélation linéaire (b) Information mutuelle (c) Notre modèle	122
5. 17	Courbe ROC pour l'évaluation des performances des algorithmes	123

Liste des tableaux

1. 1	Caractéristiques Principales du satellite QuickBird	15
1. 2	Caractéristiques principales du satellite IKONOS	16
1. 3	Caractéristiques principales du satellite Geo-Eye 1	17
1. 4	Caractéristiques principales du satellite Pleiades-1A	20
1. 5	Caractéristiques Principales du satellite TerraSAR-X	24
3. 1	Formulation mathématique de quelques descripteurs d'Harralick	50
3. 2	Résultats des différents moments de Tchebychev TRE invariants	67
4. 1	Dictionnaire des copules et leurs paramètres caractéristiques	83
4. 2	Probabilité de fausses alarmes pour différents algorithmes	89
5. 1	Paramètres de l'expérience de classification d'une chaîne de Markov couple par différents algorithmes	109
5. 2	Moyennes et variances des marginales estimées par les algorithmes des Chaînes de Markov Couple avec sélection automatique de la copule et à partir de la méthode des polynômes	110
5. 3	Taux d'erreur comparés entre différents algorithmes de segmentation	114
5. 4	Taux d'erreur pour différentes mesures de similarité des images de la figure 5.6	118
5. 5	Taux d'erreur pour différentes mesures de similarité des images de la figure 5.9	121
5. 6	Taux d'erreur pour différentes mesures de similarité des images de la figure 5.12	124

Abréviations

AR	: Auto Régressif
ARMA	: Auto Régressif à Moyenne Mobile
CC	: Coefficient de Corrélation linéaire
CMC-BI	: Chaîne de Markov cachée à bruit indépendant
CMCo-SAC	: Chaîne de Markov couple avec sélection automatique de la copule
CMCo-CNP	: Chaîne de Markov couple avec copule non paramétrique
ECI	: Estimation Conditionnelle itérative
ECIG	: Estimation Conditionnelle Itérative Généralisée
EM	: Esperance-maximisation
f.d.p.	: Fonction de densité de probabilité
f.d.r.	: Fonction de répartition
GGD	: Distribution gaussienne généralisée
GS	: Transformation de Gram-Schmidt
HS	: Image Hyperspectrale
IM	: Information Mutuelle
KLD	: Divergence de Kullback-Liebler
LIDAR	: Détection et Estimation de la distance par Laser
MCNG	: Matrice de Cooccurrence des Niveaux de Gris
MPM	: Maximum à Posteriori des Marges
MS	: Image Multispectrale
PAN	: Image Panchromatique
ROC	: Courbe Receiving Operator Characteristics
SEM	: Algorithme EM Stochastique
SS	: Image Superspectrale
SVM	: Séparateurs à Vastes Marges
THRS	: Image à Très Haute Résolution Spatiale
TRE	: Invariants par Translation, Rotation et facteur d'Echelle

Introduction

Contexte

La détection des changements à l'aide des images de télédétection est devenue l'outil principal pour analyser et suivre les changements d'occupation et d'utilisation de sols. Les auteurs de [Foley et al. 2005], puis de [Lambin et al. 2006] ont montré que ces changements participent au changement climatique global qui en retour contrôle leur évolution à échelle nationale, régionale voire locale. Ces changements vont de mutations brusques ayant une grande emprise spatiale générées par exemple par des catastrophes naturelles à des modifications subtiles et régulières affectant de petites surfaces, telles que des changements de pratiques sur des parcelles agricoles, en passant par des changements brusques et irréguliers touchant de petites superficies, comme l'étalement urbain [Lambin et al. 2001]. Leur interprétation correcte passe par leur identification, leur qualification, leur quantification mais encore par leur localisation et la détermination de l'évolution de leur empreinte spatiale. Un tel niveau de précision nécessite l'utilisation d'images à très haute résolution spatiale (THRS).

Le lancement au début des années en 1999 du satellite IKONOS par la société Space Imaging marque l'avènement d'un nouveau type de satellites, celui des satellites à très Haute Résolution Spatiale (THRS). Les capteurs de ces satellites autorisent des images avec une résolution spatiale inférieure ou égale au mètre. Les données fournies sont d'une richesse et d'une précision comparable à celle de la photographie aérienne. Le niveau de détails (par exemple, le passage d'une forêt dense à une forêt clairsemée) atteint dans ces images permet de discerner sur la surface terrestre l'organisation spatiale des objets uniquement observables jusque-là au travers de leurs propriétés spectrales dans les images de résolution spatiale plus grossière.

Problématique et méthodologie

Les images fournies par les capteurs à THRS possèdent des propriétés particulières. En premier lieu, ce type d'images conserve une bonne précision géométrique tout en assurant une bonne résolution spectrale. Pour ce faire, les satellites (satellites optiques) sont souvent équipés de deux capteurs : un panchromatique et un multispectral tandis que les radars imageurs acquièrent l'image sous différents modes selon le niveau de précision spatiale voulue. Contrairement aux photographies aériennes panchromatiques, les images panchromatiques enregistrées par les capteurs spatiaux sont sensibles au proche infrarouge, ce qui constitue un

atout de taille pour le suivi de la végétation. De plus, il est possible de fusionner les images multispectrales et panchromatiques afin d'obtenir une composition dont la résolution spatiale est égale à celle de la donnée panchromatique. En second lieu, le développement des capteurs à THRS, permet d'identifier et de caractériser des changements de faible amplitude, touchant des espaces de petites superficies, en exploitant l'organisation spatiale des objets. Cette organisation spatiale est décrite par les propriétés de la texture des objets géographiques composant l'image [Wu et al. 2012, Regniers 2014]. De plus, la résolution spectrale des capteurs diminuant avec l'augmentation de leur résolution spatiale augmente la variabilité spectrale des pixels définissant les classes d'occupation du sol [De Wit et Clevers 2004]. Cela a pour conséquence une baisse de la séparabilité entre les différentes classes d'occupation du sol et une inefficacité des méthodes d'analyse de l'image par pixel classiquement utilisées dans la détection des changements. Ce manque d'information nécessite la mise en place de méthodes de classification qui ne reposent plus uniquement sur l'information spectrale contenue dans l'image. Ainsi, il est nécessaire de développer de nouvelles approches qui s'appuient sur la texture des images à THRS.

En outre, ces approches doivent prendre en compte l'hétérogénéité des données utilisées pour détecter des changements puisqu'elles sont généralement acquises à plusieurs années d'intervalle, à différentes saisons et au moyen de capteurs ayant des propriétés spatiales et spectrales différentes. L'hétérogénéité des données constitue l'une des principales sources d'erreurs dans l'interprétation des changements [Lu et al. 2004]. Enfin, elles doivent considérer l'évolution de la forme des objets qui est susceptible d'évoluer au cours du temps.

Dans ce contexte, les méthodes d'analyse de l'image orientée objet [Blaschke, 2010] sont les plus adaptées à l'analyse de ce type d'image. Les approches « orientées-objet » peuvent être de deux ordres : soit le regroupement des pixels en objets repose sur des données auxiliaires numérisées (cartes, documents d'urbanisme, photo-interprétation) [Prendes et al. 2015], soit il s'appuie sur une segmentation au préalable de l'image en régions [Wu et al. 2012]. Dans le cas d'une intégration d'information auxiliaire, la précision des changements détectés dépendra en premier lieu de la précision des documents cartographiques et du niveau d'expertise du photo-interprète. De même, dans le cas d'une méthode reposant sur une étape de segmentation, les résultats sont dépendants de la qualité de la segmentation. Malheureusement, dans le cas de la détection des changements dans les images à THRS, le développement des outils de traitement automatique de l'image évolue mais n'est pas encore parvenue à remplacer totalement le photo-interprète. Il demeure un axe important de recherche.

Dans cette thèse, nous avons pour objectif de proposer une nouvelle méthode de détection des changements dans les images à THRS indépendante de la nature des senseurs ou capteurs impliqués dans le processus de détection des changements. Cette méthode de détection des changements utilise une approche non supervisée puisqu'elle a pour objectif de fournir des résultats comparables à ceux fournis avec l'aide d'un photo-interprète. L'approche retenue respecte le formalisme de l'approche orientée-objet lors de la classification de l'image à savoir une phase de segmentation afin d'extraire et de caractériser les objets présents et une seconde phase de classification des pixels de l'image en zone changées et zone non changées. La première phase s'appuie sur une segmentation de la paire d'images (image référence et image changement) en superpixels. Cette phase permet de regrouper les pixels en régions atomiques en fonction de leur intensité spectrale. La seconde phase comprend une phase d'extraction des attributs de texture présents dans les images afin de construire une nouvelle mesure de similarité basée sur la modélisation des dépendances par les copules. Cette phase, nous permet de créer une mesure tenant compte de la dépendance entre les images sources. Le précédent résultat est régularisé à l'aide d'une chaîne de Markov couple avec copule. Pendant la phase de construction de notre nouvelle mesure, la modélisation est effectuée de façon paramétrique tandis que dans le cas de la chaîne de Markov couple, la modélisation de la densité s'effectue de façon non paramétrique à partir de la structuration des données d'observation.

Organisation du manuscrit

Le présent manuscrit se décompose en cinq chapitres :

Le chapitre un introduit la problématique de la détection des changements dans les images de télédétection avec une attention particulière pour les images à THRS. Dans ce chapitre, nous présentons tout d'abord le contexte général de l'étude, puis la section suivante est dévolue à la présentation des différents types d'imageurs à THRS. Ce chapitre s'achève par une section sur les enjeux et les problématiques liés à la construction d'un masque de changement dans le cadre des images à THRS.

Le chapitre deux est consacré à une revue de la littérature des différentes familles de méthodes appliquées à la détection des changements dans les images de télédétection. Nous y présentons les avantages et les limites de ces méthodes. Cette revue non exhaustive des différentes méthodes présente les approches les plus utilisées en télédétection. Cette revue de littérature va des opérateurs classiques comme la différence ou le quotient initialement utilisés

aux méthodes plus complexes utilisées dans le cas des images à THRS comme les mesures de similarité statistiques adaptées aux problématiques liées à l'hétérogénéité des senseurs.

Le chapitre trois qui introduit notre première contribution est consacré à l'analyse de texture dans les images de télédétection. Une revue de la littérature des principales méthodes utilisées est effectuée. Ce chapitre s'achève par une étude autour de l'extraction des primitives de textures à l'aides des moments orthogonaux de Tchebychev invariants par translation , rotation et facteur d'échelle encore appelés moments locaux de Tchebychev TRE invariants.

Le chapitre quatre s'articule autour de la construction de la nouvelle mesure de similarité. Ce chapitre débute par une première section consacrée à la phase de segmentation. Ensuite les résultats obtenus au chapitre précédent sont utilisés en combinaison avec les résultats de la première section afin de construire la nouvelle mesure de similarité. Ce chapitre s'achève sur une phase d'expérimentation sur des images de synthèse.

Le chapitre cinq propose un nouveau classifieur non supervisé à savoir les chaines de Markov couple avec estimation non paramétrique de la copule (CMCo-CNP). Ce nouveau modèle est présenté en détail avec une phase d'expérimentation sur des images de synthèse binaires. La dernière section de ce chapitre est consacrée à la validation du nouveau modèle sur des images réelles. Trois séries d'expériences représentant les cas rencontrés dans la pratique sont effectuées. Le nouvel algorithme est d'abord évalué à l'aide d'un couple d'images homogènes provenant du même capteur satellitaire. Puis l'algorithme est évalué sur deux images optiques provenant de deux capteurs différents. Enfin, il est évalué sur deux images hétérogènes, l'image référence acquise par un capteur optique et l'image présentant le changement acquise par un radar imageur.

Chapitre 1

Position du problème

SOMMAIRE

1.1	Introduction	6
1.2.	Imagerie satellitaire à très haute résolution spatiale.....	8
1.2.1	Imageurs optiques.....	9
1.2.1.1	Caractéristiques des capteurs optiques	11
1.2.1.2	Satellites optiques.....	14
1.2.2	Radars imageurs	20
1.2.2.1.	Caractéristiques des radars imageurs.....	20
1.2.2.2.	TerraSAR-X	23
1.3.	Enjeux de la détection des changements dans les images à THRS	24
1.3.1	Enjeux de la détection de changement	24
1.3.2.	Définition de l'objet géographique et représentation numérique	26
1.3.3.	Détection des changements dans le cas des images THRS	27
1.4.	Conclusion	28

1.1 Introduction

Dans notre époque affectée par les effets néfastes du changement climatique, la maîtrise de notre environnement devient un enjeu majeur et crucial pour l'avenir de notre planète et la survie de l'espèce humaine. Cette maîtrise nécessite une meilleure connaissance des effets de l'activité humaine sur l'atmosphère ainsi qu'une meilleure compréhension des mécanismes de fonctionnement et de la dynamique d'évolution du système terrestre, des océans, de la végétation et des sols. Cette compréhension passe par l'étude de l'évolution de l'occupation et de l'utilisation des sols qui sont deux notions trop souvent confondues. Elles jouent un rôle essentiel dans la modification de la biosphère, de l'hydrosystème et des sols [Federma et al. 2005, Foley et al. 2005] et participent également au changement climatique global qui en retour les contrôlent en partie que ce soit à l'échelle globale, régionale ou locale. Elles entraînent des transformations observables sur la surface terrestre. La connaissance de ces transformations subies par les surfaces terrestres représente un enjeu primordial dans la connaissance de l'état de l'environnement actuel. Ces transformations sont généralement de deux types à savoir les conversions, c'est-à-dire du passage d'une catégorie d'occupation ou d'utilisation du sol à une autre, et les modifications qui représentent une évolution à l'intérieur d'une même catégorie suite à des changements affectant ses attributs physiques ou fonctionnels [Hubert-Moy 2004]. Ainsi, les changements de l'occupation et de l'utilisation des sols constituent un des critères principaux à prendre en considération au niveau de la mise en œuvre de décisions fondées sur le concept de développement durable, aussi bien à une échelle globale, régionale que locale.

Avant d'aller plus loin, précisons les termes d'occupation des sols et d'utilisation des sols. L'occupation des sols fait référence à la description physique de l'espace et désigne le type de couverture physique comme les forêts, les surfaces herbacées ou artificialisées, l'eau, etc... Elle peut être décomposée en deux parties que sont le sol et la végétation. Ces caractéristiques biophysiques sont observées par l'œil humain ou par des capteurs notamment ceux des satellites de télédétection. Quant à l'utilisation des sols qui est beaucoup plus complexe à définir, elle peut se traduire par l'usage socio-économique finale (fauche, pâture, fertilisation, utilisation agricole, ...) que l'homme fait de l'exploitation des différentes couvertures physiques. Par exemple une surface herbacée peut être utilisée comme surface agricole ou comme espace vert. Il en résulte donc que l'utilisation des sols affecte la nature de l'occupation qui à son tour, en fonction du service rendu, influence les changements d'utilisation des sols. Les cartographies des surfaces terrestres tirées des données de la télédétection couvrent ces deux champs

sémantiques étroitement liés. Dans la pratique courante de leur étude à l'aide des données de télédétection, une observation de l'occupation des sols permet de déduire l'utilisation des sols à partir des connaissances expertes combinées à des informations dérivées d'autres données issues de diverses cartes thématiques externes.

Jusqu'à la moitié du milieu de la première décennie du 21^{ème} siècle, seuls les changements abrupts qui caractérisent les conversions de sols étaient largement étudiés. Ces conversions permettaient de discriminer les changements intervenus à une échelle globale (échelle nationale voire régionale). A l'inverse les changements de faible amplitude qui affectent les petites surfaces, donc qui interviennent à une échelle locale et qui en sont les constituants fondamentaux sont demeurés longtemps ignorés voire insuffisamment étudiés. Les auteurs tels que ceux de [Ojuma et al. 2005] montrent que les changements d'utilisation peuvent s'expliquer par des processus intervenant à une échelle globale et à une échelle locale. En effet, la majeure partie des changements d'occupation et d'utilisation des sols interviennent à une échelle locale et la somme de leur contribution affecte de manière significative les éléments déterminants du fonctionnement à l'échelle globale du système terre (Figure 1.1).

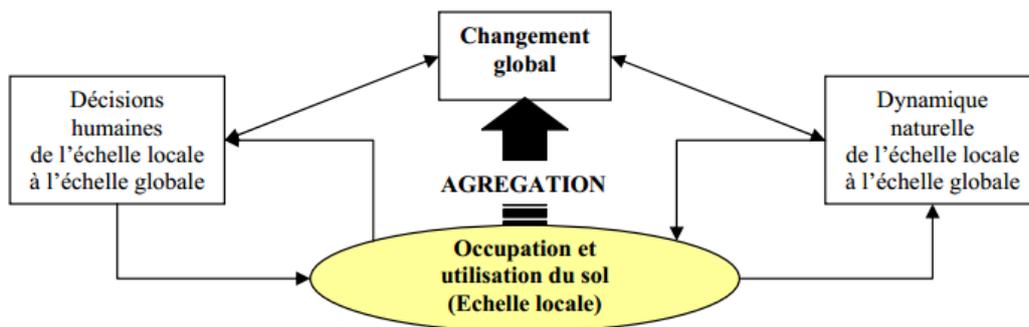


Figure 1. 1 Impact des changements d'occupation et d'utilisation des sols occurant à une échelle locale sur une échelle globale (Source : [Lecerf 2010])

Ainsi, par exemple le drainage des zones humides provoqué par une intensification agricole qui inclut une extension des terres agricoles est non ou peu perceptible à une échelle globale, mais peut localement modifier radicalement la qualité des eaux [Lefebvre 2011]. De même, l'artificialisation des terres provoquée par l'étalement urbain entraîne des conversions d'usage des sols très localisées mais qui peuvent impacter très fortement sur le fonctionnement hydrologique des zones touchées. Ce processus se traduit à travers une augmentation sensible du ruissellement de surface qui contribue au phénomène d'inondations [Lefebvre 2011].

L'avènement des satellites de télédétection à très haute résolution spatiale au début des années 2000 aussi bien dans le domaine civil que militaire a permis l'étude de l'occupation et de l'utilisation des sols de petites surfaces (dimensions de l'ordre du mètre carré) et permet l'observation des effets de leur évolution à échelle locale. Ce domaine d'étude est aujourd'hui un champ majeur de recherche au vu de l'augmentation du nombre de capteurs satellitaires et de la qualité des méthodes de traitement et d'analyse des images à très haute résolution spatiale.

1.2. Imagerie satellitaire à très haute résolution spatiale

L'imagerie satellitaire est avec la photographie aérienne l'un des outils de la télédétection. Les satellites permettent d'obtenir une représentation numérique présentant un certain nombre de caractéristiques fonctionnelles du point de vue géographique de l'énergie électromagnétique diffusée par une zone sondée. Jusqu'au début du 21^{ème} siècle, elle demeurait une source complémentaire d'informations pour la photographie aérienne. En effet, les applications étaient effectuées à partir d'images acquises par des capteurs spatiaux dont la résolution spatiale (résolution spatiale de l'ordre de la dizaine de mètres) était beaucoup plus faible que celles des photographies aériennes (résolution spatiale de l'ordre du dixième de mètre). Les données acquises étaient alors différentes dans la mesure où les capteurs satellitaires fournissaient des images à haute résolution spectrale mais avec une faible résolution spatiale alors que la photographie aérienne disposait d'images en niveaux de gris avec une forte résolution spatiale et une faible résolution spectrale. Cela a pour conséquence, l'utilisation des images fournies par les satellites lors de l'analyse des caractéristiques des zones géographiques à échelle régionale voire nationale tandis qu'une étude à l'échelle locale était réservée à la photographie aérienne. En 1999, le lancement du capteur IKONOS de la société Space Imaging marque une nouvelle étape dans la télédétection spatiale civile puisqu'il représente l'avènement d'une nouvelle génération de satellites : les satellites à Très Haute Résolution Spatiale (THRS). Avec une résolution spatiale de 1 m, IKONOS fournit des données comparables en précision spatiale à des images aéroportées et les objets géographiques analysables sur une photographie aérienne le sont désormais sur une image satellitaire. Depuis, le perfectionnement des capteurs a permis de disposer d'images capables de fournir une richesse d'informations et de détails jusqu'alors inégalées par la photographie aérienne. L'imagerie satellitaire est alors devenue le principal

outil de la télédétection même si la photographie aérienne demeure encore de nos jours largement utilisée.

Les satellites à THRS sont placés sur des orbites héliosynchrones, ce qui leur permet de toujours revisiter un même lieu à la même heure. La résolution temporelle est variable suivant les capteurs, elle est d'environ 15 jours en moyenne [Lefebvre 2011]. Ces satellites sont tous équipés de capteurs à barrettes. L'acquisition des images s'effectue à partir de cellules Charge-Couple Device (CCD) tout le long de la trajectoire de défilement du satellite. La largeur du capteur détermine ainsi la largeur de la surface observée appelée la fauchée. Les fauchées peuvent être variables d'un capteur à un autre et en fonction de la surface étudiée. Cette caractéristique est un paramètre important dans le choix de l'usage d'un capteur plutôt que d'un autre. Il est à noter que plus la résolution spatiale augmente plus la fauchée diminue. Selon que les capteurs embarqués sont la source primaire d'illumination ou non nous pouvons distinguer deux grandes familles de capteurs à savoir les capteurs optiques (capteurs passifs) et les capteurs actifs qui se subdivisent en radars imageurs et en capteurs fournissant la mesure de la hauteur d'un objet encore nommés capteurs LIDAR (Light Impulsion Detection And Ranging).

Dans ce chapitre, nous n'allons pas présenter de façon exhaustive tous les types de capteurs en imagerie satellitaire, mais nous allons plutôt nous focaliser sur ceux qui permettent l'acquisition d'images que nous allons utiliser dans nos applications. Avant toute présentation des différents capteurs, nous allons expliciter certaines notions essentielles qui caractérisent les satellites de télédétection. La première notion est la résolution spectrale qui représente à la fois le nombre de bandes spectrales et la largeur de chaque bande spectrale acquise par le satellite. La résolution temporelle représente quant à elle la durée de revisite d'une même zone par un satellite. Cette durée qui peut être variable dépend de la mobilité du satellite encore appelée agilité du satellite. Par ailleurs, la résolution radiométrique représente le nombre de bits nécessaires pour coder une image acquise par le satellite. Ainsi, une valeur de valence de 256 donne un codage sur 8 bits de chaque pixel de l'image. Enfin, la résolution spatiale détermine la taille du plus petit élément observable sur l'image acquise. On parle alors d'image à très haute résolution spatiale quand celle-ci est inférieure ou égale au mètre.

1.2.1 Imageurs optiques

Les imageurs optiques captent la lumière réfléchiée par les objets présents dans le milieu observé. La source de lumière est principalement le soleil. Les images acquises sont moins affectées par le bruit que les images radar. Néanmoins, les principaux bruits présents dans ces

images sont le bruit thermique, le bruit de capteur et le bruit atmosphérique. L'acquisition de ce type d'images est généralement limité par les conditions météorologiques (présence de nuage, visibilité faible la nuit, etc...). Les imageurs optiques couvrent généralement le domaine du visible dans le spectre électromagnétique (Figure 1.2) ainsi que le proche et le moyen infrarouge. Selon le nombre de bandes spectrales acquises, ces imageurs se distinguent en imageurs panchromatiques ou imageurs PAN fournissant des images dans le spectre visible uniquement, les imageurs multispectraux ou imageurs MS (4 bandes spectrales), les imageurs super-spectraux ou imageurs SS (8 bandes spectrales) et les imageurs hyperspectraux ou imageurs HS (plus de 15 bandes spectrales).

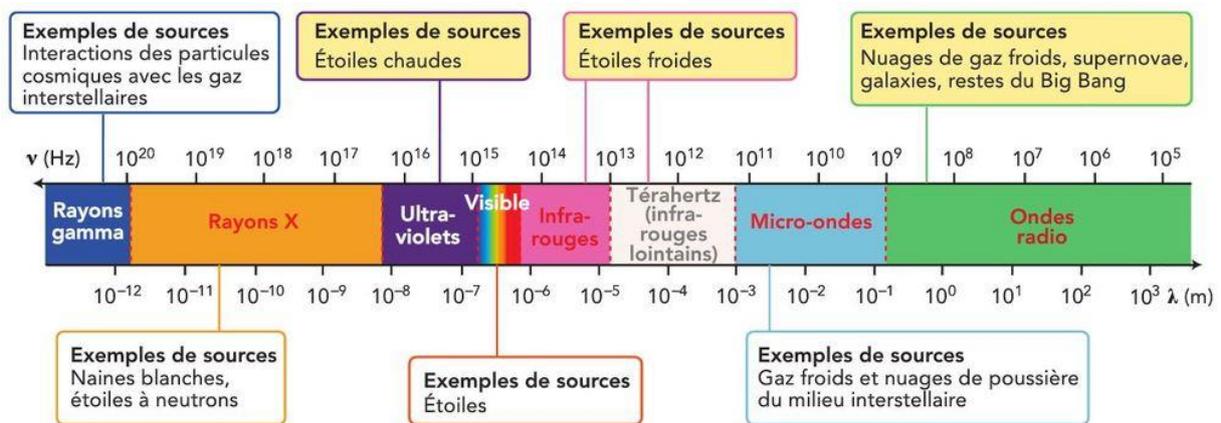


Figure 1. 2 Spectre électromagnétique (source : www.livementor.com).

Les capteurs à THRS optiques possèdent une résolution spectrale plus élevée que celle des émulsions photographiques. Afin de conserver une bonne précision géométrique des images tout en assurant une bonne résolution spectrale, les satellites sont souvent équipés de deux capteurs : un capteur panchromatique et un capteur multispectral ou hyperspectral. Contrairement aux photographies aériennes panchromatiques, les images panchromatiques enregistrées par les capteurs spatiaux sont sensibles au proche infrarouge (Figure 1.3). Cela constitue un atout de taille pour le suivi de la végétation. De plus, dans la plupart des applications, les images multispectrales et panchromatiques sont fusionnées afin d'obtenir une composition dont la résolution spatiale est égale à celle de la donnée panchromatique et qui conserve la résolution spectrale de l'image.

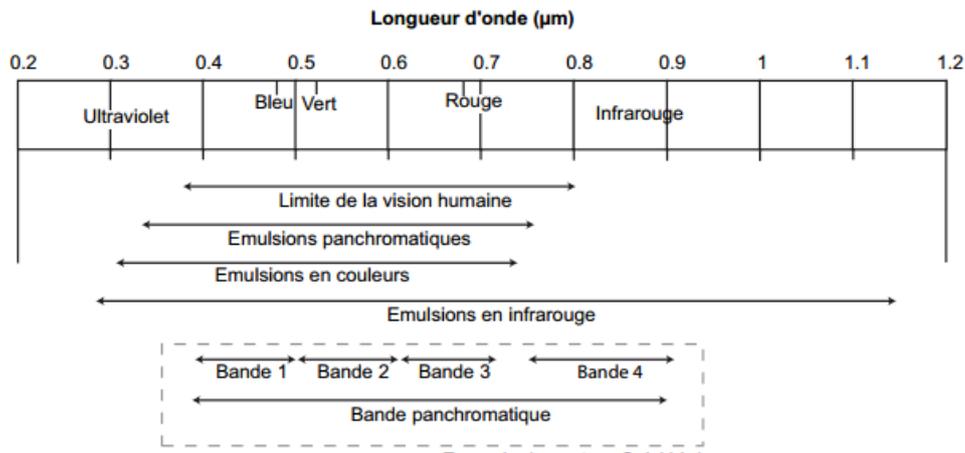


Figure 1. 3 Sensibilité spectrale du capteur QuickBird

1.2.1.1 Caractéristiques des capteurs optiques

Les capteurs panchromatiques utilisent une large bande spectrale et couvrent le domaine du visible voire du proche infrarouge pour certains imageurs tels qu'IKONOS et fournissent des images en niveau de gris. La résolution spatiale est généralement supérieure à celle fournie par les capteurs multispectraux et est généralement inférieure ou égale à 1 m. Cette large bande spectrale a pour conséquence une meilleure densité spectrale d'énergie par unité de surface. Cela permet à ce type de capteurs de fournir des images fortement texturées très riches en détails. La figure 1.4 présente la réponse spectrale de capteur panchromatique du satellite WorldView-1.

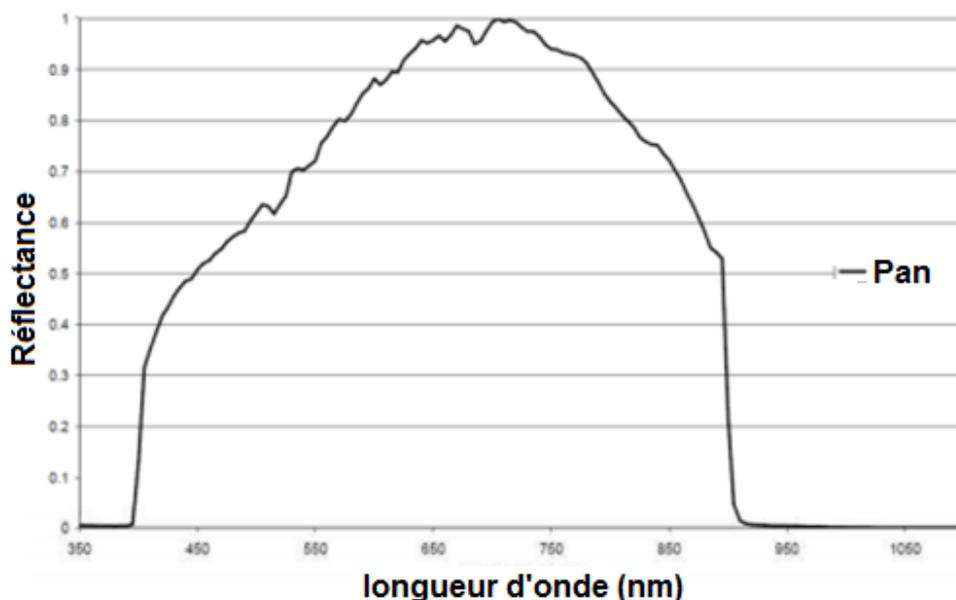


Figure 1. 4 Réponse spectrale du capteur panchromatique du satellite WorldView-1. (Source : [EL-Mezouar 2012])

Les capteurs multispectraux (MS) quant à eux fournissent des images qui résultent d'une combinaison d'images acquises dans un ensemble de bandes spectrales (généralement inférieure à 8 bandes spectrales) non nécessairement contiguës. La Figure 1.5 montre la réponse spectrale du capteur multispectral du satellite WorldView-2. Comparativement à la largeur de bande des capteurs panchromatiques, les bandes spectrales sont des bandes étroites.

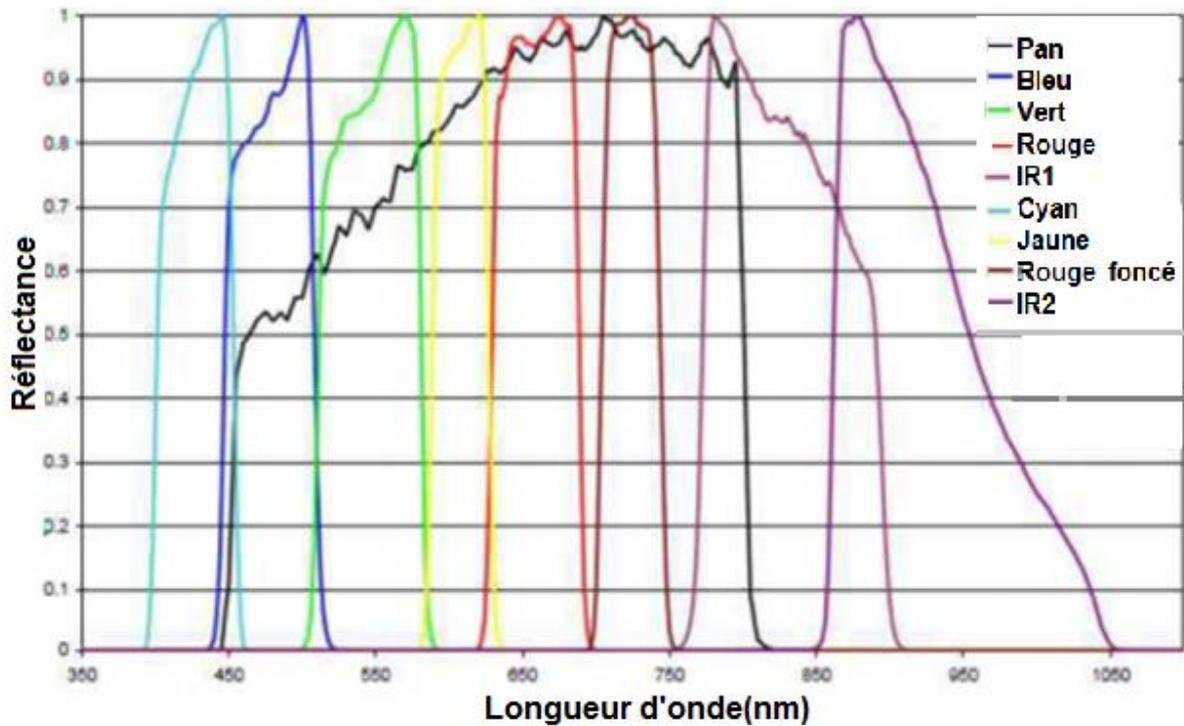


Figure 1. 5 Réponse spectrale du capteur MS du satellite WorldView-2. (Source : [EL-Mezouar 2012])

La résolution spatiale est plus faible comparativement aux images panchromatique et est de l'ordre du mètre voire de la dizaine de mètres. Elles couvrent le domaine du visible aussi bien que celui de l'infrarouge. Lorsque l'image finale est représentée à partir des bandes spectrales R, V, B on dit que l'image est en vraie couleurs, dans les autres cas, les objets sont représentés dans une couleur différente de leur couleur d'origine on parle alors de représentation en fausses couleurs. La Figure 1.6 présente une image multispectrale en vraie couleurs acquise par le satellite Pleiades et la Figure 1.7 représente une image multispectrale en fausses couleurs



Figure 1. 6 Image multispectrale en vraies couleurs du lion blanc du zoo de Whipsnade fournie par Pleiades en 2015 (Résolution 0.7m) (source @ CNES)¹



Figure 1. 7 Image SOPT multispectrale de la ville de Naples en fausse couleurs (Résolution 5m)²

La dernière famille des satellites optiques est constituée des imageurs superspectraux voire hyperspectraux. Ces imageurs acquièrent les images dans au moins dix bandes spectrales pour les capteurs superspectraux et au moins une centaine de bandes spectrales pour les capteurs hyperspectraux. Par exemple, le satellite MODIS utilise 36 bandes spectrales tandis que le capteur Hyperion du satellite EO-1 (Figure 1.8)³ utilise 242 bandes spectrales. Les capteurs utilisés sont des capteurs à bande étroite comparativement aux imageurs multispectraux. Le principal intérêt de ces imageurs est qu'ils fournissent une information plus riche et plus complète des caractéristiques des zones étudiées car elles utilisent la sensibilité d'observation

¹ <https://cnes.fr/fr/media/ispleiadeswhipsnade-lion201507032000pxjpg> (visité en mars 2017)

² http://spot5.cnes.fr/images/naples/naples_no_01.html (visité en janvier 2017)

³ http://www.hgimaging.com/HGI_Galleries_RS_Image1.htm (visité en Septembre 2017)

de certaines propriétés caractéristiques à certaines bandes de fréquences particulières. Les applications les plus importantes sont l'observation de la dynamique d'évolution des océans, de la basse atmosphère et surtout de l'agriculture de précision.

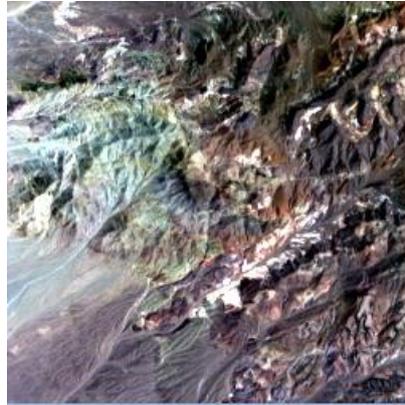


Figure 1. 8 Image de montagne dans la vallée de la mort (Nevada Californie) acquise par le capteur Hyperion en vraie couleur, Rouge=calcite, Jaune=dolomite, Violet=silice, Cyan=zéolites.

1.2.1.2 Satellites optiques

Les satellites optiques sont généralement placés sur des orbites synchrones de telle sorte qu'ils puissent revisiter une même zone à la même latitude de façon régulière. Leur orbite est généralement inclinée de 20 à 90 degrés par rapport à l'équateur. Le fonctionnement du système d'acquisition est fondé sur un télescope embarqué à bord du satellite. Dans la suite de ce manuscrit, nous allons nous focaliser sur les satellites optiques à très haute résolution spatiale tels que QuickBird, IKONOS, Pléiades, WorldView et GeoEye, pour lesquels nous allons utiliser les images dans nos différents tests.

1.2.1.2.1 QuickBird

Le satellite QuickBird est un satellite commercial lancé par la société DigitalGlobe le 16 Octobre 2001. A son lancement, il était le satellite disposant de la plus haute résolution spatiale. Il est placé sur une orbite circulaire synchrone à 600 kms d'altitude au-dessus de la surface terrestre. Il dispose d'un capteur panchromatique qui donne des images à la résolution spatiale de 0.61 m et d'un capteur multispectral qui donne des images avec la résolution spatiale de 2.4 m. La figure suivante (Figure. 1. 9) présente une vue d'artiste du satellite QuickBid tandis que le tableau 1.1 présente quelques caractéristiques techniques du satellite.

Tableau 1. 1 Caractéristiques Principales du satellite QuickBird

Caractéristiques	Valeurs
Date de lancement	18 Octobre 2001
Altitude de l'orbite	450 km
Inclinaison orbitale	91,2°
Temps de revisite	1-3,5 jours en moyenne
Résolution radiométrique	11 bits
Résolution spatiale	Panchromatique : 0,61 m Multispectral : 2.4 m
Bandes spectrales	Panchromatique, Rouge, Vert, Bleu et Proche Infrarouge



Figure 1. 9 Satellite QuickBird (Image copyright © DigitalGlobe)

QuickBird a été conçu pour couvrir de vastes étendues avec efficacité et précision. Les données issues du satellite sont exploitées pour la cartographie, la planification agricole et urbaine, la recherche météo et la surveillance militaire. Comparativement aux satellites optiques actuels à très haute résolution spatiale, il possède la plus faible résolution et s'avère incapable de distinguer les objets de très petite taille. Le 27 janvier 2015, le satellite s'est désintégré après son entrée dans l'atmosphère terrestre marquant la fin de 13 années d'activités.

1.2.1.2.2 IKONOS

Le satellite IKONOS qui est exploité par la société GeoEye a été lancé le 24 septembre 1999 depuis la base militaire de Vandenberg en Californie. Après quinze ans d'activités IKONOS a été définitivement retiré le 31 Mars 2015. Il a été le premier satellite capable de fournir des

images à haute résolution avec une précision de l'ordre du mètre. La Figure 1.10 présente le satellite IKONOS tandis que le tableau 1.2 en résume les caractéristiques techniques.

Tableau 1. 2 Caractéristiques principales du satellite IKONOS

Caractéristiques	Valeurs
Date de lancement	24 Septembre 1999
Altitude de l'orbite	681 km
Inclinaison orbitale	98,1°
Temps de revisite	Approximativement 3jours à 40° de latitude
Résolution radiométrique	11 bits
Résolution spatiale	Panchromatique : 0.82 m Multispectrale : 3.2 m
Bandes spectrales	Panchromatique, Rouge, Vert, Bleu, proche Infrarouge



Figure 1. 10 Vue d'artiste du satellite IKONOS-2 (Image copyright © GeoEye)

IKONOS dispose d'un capteur panchromatique fournissant des données avec une résolution de 1m et un capteur multispectral fournissant des données avec une résolution de 4 m dans la bande visible et infrarouge. L'altitude orbitale est de 680 km. Les images produites par IKONOS comptent parmi les images satellitaires les plus détaillées qu'il soit possible de se procurer dans le cadre d'applications civiles. Il permet de réaliser une cartographie de l'utilisation du sol.

1.2.1.2.3 GeoEye

Le satellite GeoEye est en fait composé de deux satellites GeoEye-1 (Figure 1.11) lancé en 2008, et GeoEye-2 qui était prévu pour être lancé en 2013. Après le rachat de la société GeoEye par DigitalGlobe en 2013, le satellite GeoEye-2 a servi de base au développement du satellite WorldView-4. GeoEye dispose de 3 capteurs : un capteur panchromatique avec une résolution spatiale de 0.41 m, un capteur multispectral opérant dans le visible avec une résolution de 1.65 m et un capteur proche infrarouge. Il est à noter que le gouvernement américain impose la fourniture d'images panchromatiques dans le domaine civil à une résolution de 50 cm. Les satellites de la famille GeoEye sont les principaux fournisseurs de données de Google Maps et de Google Earth. Le satellite GeoEye-1 demeure encore en activité à cause de ses importantes réserves d'ergols restants malgré le dépassement de la date de fin de la mission prévue. Le tableau suivant resume les principales caractéristiques de Geo-Eye 1.

Tableau 1. 3 Principales caractéristiques du satellite Geo-Eye 1

Caractéristiques	Valeurs
Date de lancement	06 Septembre 2008
Altitude de l'orbite	684 km
Inclinaison orbitale	98°
Temps de revisite	2 jours en moyenne
Résolution radiométrique	11 bits
Résolution spatiale	Pan : 0.41 m Multispectral : 1.65 m
Bandes spectrales	Panchromatique, Rouge, Vert, Bleu et Proche Infrarouge



Figure 1. 11 Image du satellite GeoEye-1 (Source © DigitalGlobe)

1.2.1.2.4 WorldView

La famille des satellites WorldView est composée des satellites WorldView-1 lancé en 2007, WorldView-2 lancé en 2009, WorldView-3 en 2013 et depuis septembre 2016 du satellite WorldView-4. Le satellite WorldView-4 est construit autour de l'architecture du satellite GeoEye-2 suite au rachat par DigitalGlobe de la société GeoEye en 2013. Les satellites WorldView disposent d'un capteur panchromatique de résolution spatiale de 0.31 m (WorldView3 et WorldView-4) et de 0.46 m (WorldView-2) et d'un capteur multispectral. Par exemple le satellite WorldView-2 (Figure 1.12) dispose d'un capteur multispectral à 8 bandes (Rouge, Frontière du rouge, Vert, Cyan, Bleu, Jaune, proche Infrarouge 1, proche Infrarouge 2), alors que le satellite WorldView-4 opère dans 4 bandes (Rouge, Vert, Bleu et proche Infrarouge). Une amélioration de l'agilité du satellite autorise l'acquisition d'images de grandes superficies lors d'un seul passage. La diversité spectrale des images fournies permet de détecter les changements de façon plus précise. De plus, les temps de revisite sont assez faibles comparativement aux autres capteurs optiques à THRS. Les domaines d'application vont de la télédétection civile à la télédétection militaire



Figure 1. 12 Image du satellite WorldView-2 (source © DigitalGlobe)

1.2.1.2.5. Pléiades

Pleiades est une constellation appartenant au Centre National d'Etudes Spatiales (CNES) et composée de deux satellites Pleiades-1A et Pleiades-1B (Figure 1.13) opérant sur une orbite héliosynchrone décalés de 180° l'un par rapport à l'autre. Chaque satellite dispose d'un capteur panchromatique fournissant des images avec une résolution spatiale de 0.7 m et d'un capteur multispectral à quatre bandes (Rouge, Vert, Bleu et proche infrarouge) avec une résolution spatiale de l'ordre de 2.8 m. La principale force de ces satellites est leur instrument optique doté d'un détecteur extrêmement sensible qui permet une réduction du temps d'exposition nécessaire à la production de chaque cliché, permettant d'obtenir un plus grand nombre d'images par jour (500 images par jour et par satellite). La principale caractéristique de Pléiades est la réduction notable du temps de revisite d'une même zone sondée. L'information fournie par les satellites est complémentaire de celle fournie par les satellites SPOT et couvre les champs d'application de la télédétection civile que militaire. Dans le tableau 1.4 est résumé les principales caractéristiques du satellite Pleiades dans sa version 1A.

Tableau 1. 4 Principales caractéristiques du satellite Pleiades-1A

Caractéristiques	Valeurs
Date de lancement	16 Décembre 2011
Altitude de l'orbite	694 km
Inclinaison orbitale	98°
Temps de revisite	1 jours en moyenne
Résolution radiométrique	11 bits
Résolution spatiale	Panchromatique : 0,7 m Multispectral : 2.8 m
Bandes spectrales	Panchromatique, Rouge, Vert, Bleu et Proche Infrarouge



Figure 1. 13 Satellite Pléiade (Source © CNES)

1.2.2 Radars imageurs

1.2.2.1. Caractéristiques des radars imageurs

Le terme radar issu de l'acronyme anglais Radio Detecting And Ranging, utilise un capteur actif contrairement aux imageurs optiques qui eux sont qualifiés de passifs car ils se contentent de capturer la lumière réfléchiée par un objet situé à la surface terrestre. Les imageurs actifs au contraire se composent d'un émetteur, qui est la source du rayonnement et d'un détecteur qui mesure le rayonnement rétrodiffusé par la surface observée. Ils utilisent les hyperfréquences (fréquences comprise entre 1 GHz et 100 GHz) et permettent d'analyser la position, la vitesse de déplacement des objets étudiés. Si l'objet rétrodiffusé se trouve à la distance r du satellite, nous avons :

$$r = \frac{ct}{2} \quad (1.1)$$

avec c = vitesse de déplacement de l'onde électromagnétique, t = durée du trajet aller-retour de l'onde.

Ces imageurs ont une particularité importante car ils sont insensibles aux conditions atmosphériques et peuvent être utilisés en tout-temps. Ils s'utilisent très souvent comme source d'information complémentaire aux imageurs optiques, surtout dans l'observation à court terme des changements intervenus sur une surface observée de la terre. Ainsi, Brunner et al. [Brunner et al. 2010a, Brunner et al. 2010b] combinent l'usage des imageurs radars et des imageurs optique à très haute résolution afin de mesurer les effets des dommages en environnement urbain. Par exemple, les auteurs de [Koffi et al. 2014] utilisent conjointement les images optiques et radar (Figure 1.14) afin d'aider à la prospection minière par la détection des zones de fracture majeure dans la localité de Tiebissou.

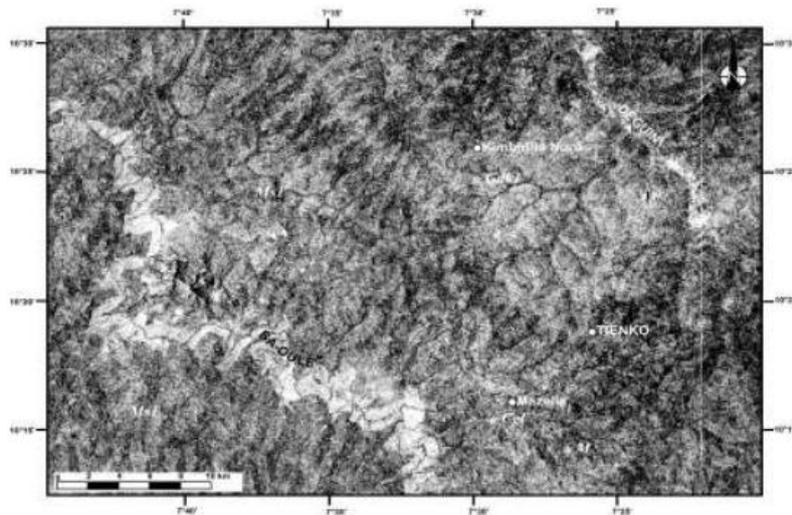


Figure 1. 14 Image en négatif de la localité de Tienko prise par le radar ERS-1 prise en 1992 (Source : [Koffi et al. 2014])

Parmi les imageurs radar, les radars à Synthèse d'Ouverture (RSO) [Olivier 2004, Massonnet 2008] sont ceux qui nous intéresseront par la suite. Ce sont des radars à visée latérale c'est-à-dire que dans ces imageurs, l'antenne du radar émet latéralement un rayonnement micro-onde qui vient « illuminer » une portion de surface allongée perpendiculairement au déplacement du satellite. La figure (Figure 1.15) suivante illustre le principe.

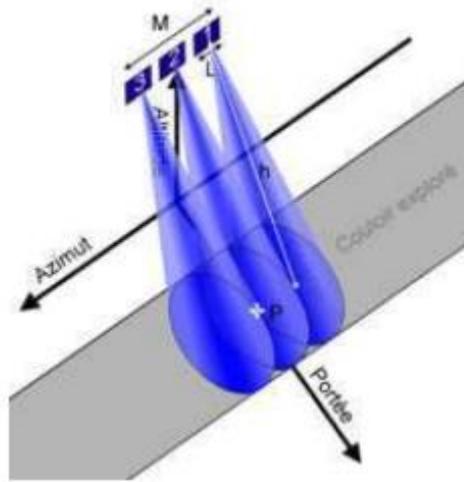


Figure 1. 15 Principe du radar à synthèse d'ouverture(RSO) (Source : Wikipédia)

La synthèse d'ouverture est une technique permettant d'obtenir des images de très haute résolution spatiale à partir d'un post-traitement à l'aide de la transformée de Fourier. Le principe de ce type de radar est similaire à celui d'une antenne réseau à commande de phase. L'image finale de l'objet est obtenue après traitement de l'image composite obtenue par de multiples sondages successifs décalés dans le temps et dans l'espace. En effet, une surface observée n'occupe qu'une partie du faisceau pendant la phase d'illumination. L'intensité et la phase du signal rétrodiffusé est fonction alors de sa position relative au porteur du radar (Figure 1.15). L'image finale est la somme des différentes contributions des multiples sondages de la zone observée. La transformée de Fourier inverse de cette sommation aboutit au calcul d'un nouveau point comme si celui-ci était acquis par une grande antenne améliorant ainsi la résolution de l'image. Cependant, pour les applications les plus simples, la donnée de la phase n'est pas prise en compte ce qui permet d'obtenir des images planes de la zone observée.

L'analyse des images radar est plus complexe que celle des images optiques. En effet, les images radar sont essentiellement affectées par du bruit à texture appelé « bruit poivre-sel » qui traduit la présence du phénomène de chatoiement. Ce phénomène est dû à l'addition cohérente de l'énergie rétrodiffusée par les différents constituants de la zone sondée. Cette addition pouvant être constructive (zones claires) ou destructives (zones sombres). Ce bruit est de type multiplicatif et affecte les images radar depuis leur acquisition. Le traitement du phénomène de chatoiement repose sur deux approches : les traitements multi vues et le filtrage spatial adaptatif. Le traitement multi vues acquiert l'image de la zone sondée sous plusieurs angles de visée et construit l'image résultante par calcul de la moyenne des différentes acquisitions.

Quant au traitement par filtrage introduit par Lee [Lee et al. 1994], il consiste à appliquer une fenêtre glissante de quelques pixels à chaque pixel de l'image et à moyenniser les pixels de cette fenêtre suivant une certaine pondération. Afin d'améliorer les résultats obtenus, d'autres filtres plus complexes ont été mis en œuvre [Huan 1996, Sheng 1996, Mansourpour 2006, Kupidura et Koza 2008, Argenti 2013]. Cependant, dans le cas des images à haute résolution spatiale, l'application des méthodes de filtrage dégrade la résolution de l'image, ce qui altère les détails fins contenus dans l'image. De plus, le bruit de chatoiement est corrélé au signal et dans le cas des images à haute résolution, ce bruit contient également des informations utiles à l'analyse de l'image [Voisin 2012].

1.2.2.2. TerraSAR-X

TerraSAR-X(TSX) désigne une famille de satellites jumeaux TerraSAR-X (Figure 1.16) lancé en 2007 et TanDEM-X (TerraSAR-X add-on for Digital Elevation Measurements) lancé en 2010 afin de fournir des images interférométriques. Il est le fruit d'un partenariat public-privé entre l'agence spatiale allemande (DLR) et EADS Astrium Allemagne.

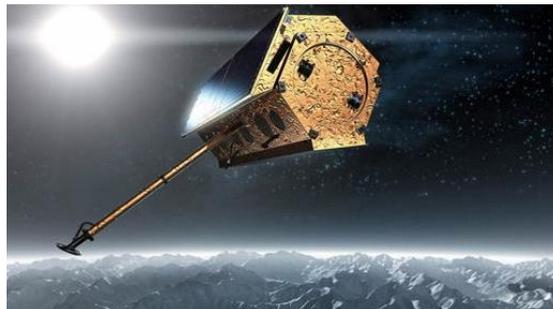


Figure 1. 16 Vue d'artiste du satellite TerraSAR-X (Source @ AIRBUS Defence & Space)

Les domaines d'application vont de la télédétection militaire à la télédétection civile dans laquelle il est utilisé pour des applications en hydrologie, en géologie, en climatologie, en gestion des catastrophes environnementales. Les satellites opèrent dans la bande X et les temps de revisite varient de 1 à 3 jours pour des zones spécifiques, et sont de 11 jours pour des zones situées à l'équateur. Le tableau 1.3 donne les principales caractéristiques techniques du satellite TerraSAR-X. Quatre principaux modes d'acquisition sont utilisés avec différentes résolutions spatiales :

- le mode SpotLight est celui qui donne les meilleures résolutions spatiale (1,1 mètre en polarisation simple et 2,2 mètres en multi polarisation) sur de petites zones (5×10 km).

- Le Mode Spotlight pour des résolutions de 1,7 mètre en polarisation simple et 3,4 mètres en multi polarisation sur des petites zones (10 × 10 km) ;
- le Mode StripMap qui est le mode d'acquisition par défaut, pour des résolutions de plusieurs mètres (autour de 3 mètres en polarisation simple, 6 mètres en mode PingPong) permettant l'acquisition de zones de plusieurs dizaines de kilomètres (autour de 30 × 30 km) ;
- le Mode ScanSAR pour des résolutions de 18,5 mètres, permettant l'observation de zones très étendues (zones de plus de 100 × 150 km).

Dans cette thèse, nous utiliserons les images acquises par le satellite TerraSAR-X dans le mode SpotLight.

Tableau 1. 5 Caractéristiques Principales du satellite TerraSAR-X

Caractéristiques	Valeurs
Orbite	Héliosynchrone
Temps de revisite	11 jours
Inclinaison	97.44°
Altitude à l'Equateur	514 km
Fréquence centrale	9.65 GHz (Bande X)
Largeur de Bande	150 MHz/ 300 MHz
Polarisation	Simple ou double en fonction du mode d'acquisition de l'image

1.3. Enjeux de la détection des changements dans les images à THRS

1.3.1 Enjeux de la détection de changement

La détection des changements dans les images consiste à construire une image qui traduit les différences les plus significatives survenues entre deux images ou une séquence d'images d'une même scène acquises à des instants différents. Le but principal de la détection des changements dans une paire d'images ou dans une séquence d'images est selon [Radke et al. 2005] la discrimination des régions changées dans les différentes images de la même scène acquise à des instants différents. Cette vue globale de la détection des changements en fait l'une des applications les plus essentielles dans des domaines aussi variés tels que l'imagerie médicale,

la sécurité urbaine, l'agriculture de précision ou encore la télédétection. Cependant, cette définition soulève des difficultés spécifiques que doit chercher à résoudre tout traicteur d'images face à ce problème :

(A) Le premier problème est lié à la phase d'acquisition des images. En effet, les images peuvent être acquises soit par différents types de capteurs. Cela entraîne qu'une même scène peut être représentée différemment selon la nature du capteur (optique/radar ou panchromatique/multispectrale par exemple), soit par des capteurs de même type mais avec des conditions d'illumination différentes (angles de prise de vue différents), soit avec des capteurs de même famille mais à des résolutions spatiales, spectrales ou radiométriques différentes.

(B) Le second problème est le nombre d'images qui peut varier d'une paire d'images à une séquence d'images fixes ou vidéo.

(C) Le troisième problème qui est certainement le plus difficile est celui de l'interprétation de la notion de zones changées dans une scène contenue dans une image.

Les problèmes (A) et (B) sont résolus par les méthodes de recalage de l'image qui constituent une étape de prétraitement nécessaire à toute méthode de détection des changements. Les méthodes de recalage consistent en la mise en correspondance géométrique d'un couple ou d'une série d'images. Certains auteurs tels que Day et Khorran [Day et Khorran 1998] ont montré qu'une erreur de recalage de l'ordre d'un cinquième de pixel serait responsable d'environ 10% d'erreurs de détection. Le problème (C) quant à lui adresse celui de la construction du masque de changement. Ce masque est une image binaire qui présente de façon univoque et sans ambiguïté l'ensemble des changements intervenus sur les différentes scènes dans les images. Ce problème n'admet pas de solution générique et les méthodes développées sont généralement adaptées au type d'applications et à la nature des capteurs utilisés. Les premières approches ont été consacrées aux méthodes de détection de changements pour les images homogènes c'est-à-dire des images acquises avec des capteurs présentant les mêmes caractéristiques techniques ou appartenant à la même famille de capteurs (optiques ou radar). Une nouvelle tendance qui s'est accélérée avec l'avènement au début des années 2000 des imageurs satellitaires à très haute résolution spatiale (THRS) est la construction des masques de changement à partir d'images hétérogènes acquises par une grande diversité de capteurs.

Dans la suite de ce manuscrit, nous allons nous intéresser à la détection des changements à base d'images THRS permettant un suivi de l'évolution des ressources naturelles. Détecter les

changements survenus ne se limite pas à la seule identification du changement mais inclut également la prise en compte de l'aspect spatial MacLeod et Congalton [MacLeod 1998]. Des auteurs comme Khorran [Khorran 1999] et plus tard Blaschke [Blaschke 2003] ont montré que les changements observés sur la surface terrestre sont la combinaison de plusieurs facteurs à savoir l'apparition et la disparition des objets, les changements de localisation et de forme de ces objets. Malheureusement, cette approche ne tient pas compte des modifications internes aux objets qui sont liées à un changement d'état de surface de ceux-ci et qui jouent un rôle important dans le changement de ces objets. Cela a pour conséquence de ramener la détection des changements dans une paire d'images ou dans une séquence d'images à la discrimination et à l'interprétation des changements intervenus dans les objets contenus dans les images. La seule identification des changements de l'intensité spectrale des pixels entre ces images est alors insuffisante. La principale difficulté provient alors de l'interprétation de la notion d'objet géographique selon l'application désirée et selon la résolution des images mises en jeu. Pour la suite de notre étude, nous allons définir la notion d'objet géographique, et aborder leur modélisation numérique

1.3.2. Définition de l'objet géographique et représentation numérique

La détection des changements passant par la connaissance des changements intervenus au sein des objets constituant l'image, il est nécessaire de bien définir la notion d'objet géographique afin de faciliter une analyse des images. Ainsi Robin dans [Robin 1995] a adapté la définition proposée par Brunet et al. en 1993 [Brunet et al. 1993] qui définit un objet géographique comme une entité qui a une dimension dans l'espace, qui met en jeu des lieux, et qui possède d'intéressantes propriétés fonctionnelles du point de vue de la géographie. La nouvelle définition proposée par Robin est une définition de référence jusque-là utilisée en télédétection et indique que : *« L'objet géographique est défini, dans le paysage, comme un élément à l'interface hydrosphère-atmosphère, lithosphère-atmosphère ou biosphère-atmosphère. Il est doté d'une surface caractérisée par un ensemble de valeurs radiométriques et est délimité par d'autres éléments caractérisés par d'autres valeurs radiométriques. La forme et l'organisation des valeurs radiométriques de l'élément du paysage sont révélatrices de son identité, au même titre que sa signature spectrale ».*

Plus simplement, un objet géographique peut être vu comme une entité indépendante composée de plusieurs lieux de la surface de la terre possédant des caractéristiques propres

fonctionnelles du point de vue géographique (champ, réseau routier, ville, immeubles, distribution spatiale,...) permettant de l'identifier de façon unique.

Sur une image numérique, un objet est représenté par un groupe de pixels. Une partie d'entre eux généralement situés au centre de l'objet sont appelés pixels purs. Ils permettent de caractériser l'objet géographique à partir de leurs caractéristiques spectrales (intensité, luminance) et de leur arrangement spatial (textures). Une autre partie des pixels situés eux en bordure de l'objet sont appelés pixels mixtes et traduisent les interactions de l'objet avec son environnement. La précision de l'analyse de l'objet repose sur le rapport entre pixels purs et pixels mixtes et est intimement liée à la résolution spatiale de l'image. En effet, plus la résolution spatiale est fine plus les objets contiennent un nombre important de pixels purs. A l'inverse le nombre de pixels mixtes augmentent au fur et à mesure que la résolution diminue et que la taille des pixels se rapproche de celle des objets. Dans les images à très haute résolution spatiale, la résolution est suffisamment fine pour que la majorité des pixels caractérisant les objets soient des pixels purs. Cela permet de mettre en évidence les détails contenus dans les objets. De plus, au sein d'un même objet l'homogénéité de la valeur numérique des pixels varie en fonction de l'hétérogénéité spectrale de l'objet analysé.

1.3.3. Détection des changements dans le cas des images THRS

L'analyse et le traitement des images à THRS par les méthodes traditionnelles de détection de changement se heurtent à des difficultés majeures. En effet, comme indiqué dans les paragraphes précédents (cf. sections 1.3.1 et 1.3.2), la qualité des méthodes de détection de changements est fortement liée à l'interprétation que l'on fait de la notion d'objet géographique et de sa représentation numérique. Dans le cas des images à basse, moyenne ou haute résolution spatiale, le pixel pris individuellement était représentatif d'un objet géographique puisqu'alors l'intensité spectrale d'un pixel représentait l'intensité spectrale d'une grande zone homogène. Cela n'est plus le cas avec les images à très haute résolution spatiale. De plus, la résolution spectrale baisse avec l'augmentation de la résolution spatiale tandis que leur variabilité spectrale augmente. Donc une analyse uniquement basée sur la seule information spectrale contenue dans les pixels de l'image se trouve limitée par la faiblesse de la résolution spectrale de ceux-ci [Fisher 1997, Johannsen et al. 2010] et les résultats obtenus manquent de cohérence spatiale. Pour faire face à ses limitations, l'analyse d'image à base d'objets traite non plus les pixels mais les objets qui sont des regroupements de pixels adjacents selon un critère d'homogénéité qui tient compte d'une mesure de similarité pour la prise en compte de toute

l'information contenue dans les images et des traitements à réaliser. Plusieurs études ont été menées qui montrent que l'analyse d'images à très haute résolution spatiale à base d'objets donne de meilleurs résultats comparativement aux méthodes traditionnelles basées sur les pixels [Boyd et Foody 2011]. La classification d'images à base d'objets s'effectue généralement en deux étapes : une première étape de création des objets contenus dans les images et une seconde étape de classification de ces objets. La première étape s'appuie généralement sur une technique de segmentation de l'image en régions homogènes. Cette segmentation s'effectue en prenant en compte aussi bien les paramètres spectraux de l'image que les informations texturales, géométrique et contextuelle. Les régions ainsi obtenues sont les unités de base utilisées pour les traitements ultérieurs. Malheureusement, l'estimation automatique des paramètres intervenant dans le processus de segmentation permettant l'extraction des objets demeure un enjeu crucial pour l'approche objet [Dragut et al. 2010, Martha et al. 2011, Hernando et al. 2012, Lein 2012]. Cela prouve toute l'importance à accorder à cette étape de segmentation. L'étape de classification utilise soit des méthodes de règles à base de connaissance des régions (méthodes du plus proche voisin), soit des méthodes basées sur les attributs spectraux, texturaux, géométriques et contextuels des objets de l'image, et ce avec généralement la présence d'un expert du domaine d'application. Cela présente une des limitations de l'approche objet dans le développement des méthodes automatiques de détection de changements.

Afin de pallier la nécessité de recourir à un photo-interprète pour la définition des objets lors de la définition des méthodes non supervisées de détection des changements à THRS, des auteurs comme Wu et al. en 2012 [Wu et al. 2012] ont proposé l'utilisation des superpixels lors de la phase de segmentation. Dans ce cas, l'image est sur-segmentée et les pixels sont alors regroupés en blocs homogènes en fonction de leur similarité spectrale et de leur adjacence spatiale. L'intérêt de cette décomposition vient du fait qu'un objet est vu comme un ensemble de superpixels qui forment un ensemble de sous-objets le caractérisant.

1.4. Conclusion

Dans ce chapitre introductif, nous avons présenté la problématique du suivi de l'utilisation et de l'occupation des sols. Ce suivi de l'utilisation et de l'occupation des sols qui s'effectue de plus en plus à une échelle locale nécessite la détection des changements dans les images de télédétection par satellites. L'usage des satellites à très haute résolution spatiale permet la détection des changements à échelle locale. Cependant, leur analyse ne peut se limiter

uniquement à la seule prise en compte de l'intensité spectrale des pixels pris individuellement, mais impose de définir des regroupements de pixels en fonction de leur intensité spectrale, de leurs attributs texturaux et du contexte spatial. Deux solutions sont alors possibles : l'approche objet qui donne de meilleurs résultats dans les méthodes supervisées de détection de changements et l'approche par superpixels qui s'adapte bien aux cas des méthodes non supervisées. Quel que soit la méthode utilisée, la détection des changements s'appuie sur l'utilisation d'opérateurs permettant de caractériser et de discriminer ces changements. Le chapitre suivant sera consacré à une revue de la littérature des principaux opérateurs les plus utilisés en télédétection. Nous irons des opérateurs algébriques adaptés à une approche pixel à des opérateurs plus complexes permettant de construire des matrices de similarité plus adaptées à l'étude des changements dans les images à THRS

Chapitre 2

Etat de l'art des méthodes de détection des changements

Sommaire

2.1. Introduction	31
2.2. Détection des changements dans les images optiques	32
2.3. Détection des changements dans les images radars.....	35
2.4. Détection des changements à base de mesure de similarité	37
2.4.1. Coefficient de corrélation linéaire	39
2.4.2. Information mutuelle	41
2.4.3. Divergence de Kullback-Liebler	43
2.5. Conclusion	44

2.1. Introduction

Dans le chapitre un, nous avons indiqué que la détection des changements dans les images recouvre deux problèmes, celui de la mise en correspondance des images et celui de la construction du masque de changement. Dans la suite de ce mémoire, nous allons nous focaliser sur le problème de la construction du masque de changement et considérer que les images sont mises en correspondance. Dans ce chapitre, nous allons présenter les méthodes développées dans le cadre des images homogènes optiques et radar. Plus particulièrement, nous allons porter notre attention sur les méthodes à base de mesure de similarité qui constituent le socle des méthodes adaptées à la détection des changements pour capteurs hétérogènes. Nous avons montré que les premières applications ont été développées d'abord selon le type d'application et donc selon le type de capteurs. Préalablement ces méthodes ont été développées pour les capteurs optiques puis ont été tendues aux images radars. L'arrivée des imageurs à très haute résolution spatiale aussi bien dans le domaine civil que militaire au début des années 2000 a entraîné une augmentation de la diversité des sources d'informations et la disponibilité d'une plus grande richesse d'informations jusque-là encore inégalée avec les imageurs précédents. Les informations sont disponibles à des résolutions spatiales, spectrales ou radiométriques différentes, avec des capteurs de types différents et dans le cas de capteurs de même famille, avec des conditions d'acquisition différentes. Cependant, leur analyse et leur interprétation nécessite l'usage de prétraitements notamment la fusion des images panchromatiques et multispectrales dans le cas des images optiques, voire des images optiques et radar de la même scène acquise. Dans la section 1.3 du chapitre précédent, nous avons montré que leur analyse nécessite le développement de nouvelles méthodes prenant en compte l'information spectrale et texturale [Voisin 2012]. Cela a eu pour conséquence d'une part la mise au point de nouvelles méthodes adaptées à la détection des changements notamment le développement de méthodes hybrides combinant information spectrale et texturale [Lefebvre 2011] et l'analyse à base objets [Walker 2004, Chen et al. 2012]. De plus dans le cas d'images hétérogènes, plusieurs méthodes adaptées à cette hétérogénéité des capteurs et des conditions d'acquisition des images ont été mises au point.

Les toutes premières approches proposées utilisées ont été tout d'abord développées pour les images optiques avant leur extension aux images radars. D'autres études ont suivi pour combler les limitations des premières techniques et se sont développées surtout à l'avènement des capteurs à THRS. Plusieurs classifications ont été proposées selon le niveau (niveau pixel,

niveau des descripteurs, niveau décisionnel) auquel s'effectue la construction du masque de changements ou selon que la détection des changements s'effectue directement à partir des images sources (méthodes directes) ou après transformation de celles-ci (méthodes post-classification). Néanmoins quel que soit le niveau décisionnel, ce sont les mêmes opérateurs que l'on adapte aux caractéristiques recherchées. Dans la suite, notre étude se fera selon le type de capteurs et en passant en revue les principaux opérateurs utilisés.

2.2. Détection des changements dans les images optiques

Les premières techniques utilisées se sont appuyées sur les méthodes de comparaison temporelle des intensités de niveaux de gris entre images. Ces comparaisons sont le plus souvent effectuées au niveau pixellaire et étaient les plus utilisées jusqu'au milieu des années 2000. Ces techniques s'appuient sur des opérations algébriques comme la différence [Singh 1989, Inglada 2001, Radke et al. 2005] ou le quotient [Rigniot 1993, Coppin 1994, Bazi 2005] afin de mettre en évidence les différences d'intensité entre images acquises à des dates différentes. Dans le cas d'images multispectrales, une approche naturelle serait de considérer la contribution de chaque canal représentant une bande spectrale. La quantité de changement est vue comme la somme des contributions des changements dus aux différentes bandes [Bovolo et Bruzzone 2007]. Cependant, ces méthodes nécessitent souvent un seuillage ou une règle de décision afin de délimiter les limites entre les zones [Inglada 2001]. Elles sont très sensibles aux bruits dans les images, aux erreurs de recalage et aux variations des conditions d'acquisition des images aux dates différentes. Les résultats obtenus font souvent apparaître un taux élevé d'alarmes de changements non pertinents [Pajares 2005]. Afin de réduire leur sensibilité aux bruits, ces méthodes sont appliquées sur des moyennes calculées sur une fenêtre généralement rectangulaire centrée autour du pixel d'intérêt. Cette prise en compte de ce voisinage produit une classification plus homogène. Dans la pratique le choix des fenêtres est effectué de façon empirique et ce sont généralement des fenêtres carrées de 3×3 pixels à 15×15 pixels qui sont utilisées.

Afin de pallier les insuffisances des techniques précédentes et face à la variabilité des conditions d'illumination des capteurs satellitaires, des méthodes basées sur une transformation globale de l'image en une image résultante ont été proposées. Cette transformation permet de réduire l'information redondante entre les bandes et d'accentuer les changements entre les

différentes composantes de l'image. Ces méthodes sont l'analyse en composantes principales (ACP) et ses dérivées, la transformation "Tasseled Cap" (KT), la matrice de Gramm-Schmidt (GS) et la transformation Chi-carré [Inglada 2001]. Leur principale limitation est qu'elles ne sont pas capables de fournir des matrices détaillées des changements intervenus dans l'image et nécessitent souvent un seuillage afin d'isoler les principaux changements intervenus dans les images. Un autre inconvénient de ces techniques est leur incapacité à détecter les changements survenus sur des bandes dérivées. Plus récemment, l'utilisation de la transformée en ondelettes [Celik 2009a, Celik 2010a, Moser et al. 2011] combinée à un usage des opérateurs de différence a permis d'améliorer la robustesse aux bruits des méthodes algébriques.

Une autre possibilité importante est l'utilisation du principe du « Soft Computing » afin de détecter les changements dans les images. Cette approche intègre l'imprécision et l'incertitude dans la prise de décision dans les modèles informatiques et essaie de reproduire au mieux le fonctionnement du cerveau humain. Les différentes méthodes composant cette approche s'utilisent de façon collaborative et font actuellement l'objet d'intenses recherches. Cette catégorie inclue les approches floues [Metternicht 1999, Bruzzone et Prieto 2009, Fisher et al. 2006, Kennedy et al. 2009], les réseaux de neurone [Woodcock et al. 2001, Nemmour et Chabani 2006, Gosh, Subudhi et Bruzzone 2013], les classifieurs de type Séparateur à Vastes Marges (SVM) [Huang et al. 2008, Longbotham et al. 2012, Hussein et al. 2013] et les approches évolutionnistes telles que les approches génétiques [Sagnika et al. 2014]. Malheureusement, ces approches n'exploitent pas toutes les propriétés de l'information contenue dans les images.

L'avènement au début des années 2000 des images satellites à THRS telles que celles fournies par les satellites QuickBird, GeoEye, etc..., ont ouvert de nouvelles perspectives pour la cartographie des territoires. Il devient possible de combiner l'information en provenance de plusieurs THRS [Prendes 2015] ou de combiner l'information provenant de source THRS avec des informations provenant de sources traditionnelles [Colin-Koeniguer et F. Janez 2013]. Les méthodes de détection des changements basés sur l'approche objet sont une extension des méthodes d'analyse de l'image à base d'objets. Ces méthodes comprennent deux étapes essentielles : une première phase de segmentation et d'extraction des caractéristiques de l'objet et une seconde phase d'application d'une stratégie de classification [Benz et al. 2004, Blaschke 2010]. Chen et al. [Chen et al. 2012] ont proposé de regrouper ces méthodes en 3 classes :

(a) la détection des changements à base d'objet par approche directe qui compare les objets de différentes images par analyse de leur statistique (moyenne, variance,...) [Hall et Hay 2008, Lefèvre et al. 2008, Tommowski et al. 2011, Niemeyer et al. 2008] ;

(b) la détection des changements par classification d'objets dans laquelle les objets de chaque image sont extraits et classifiés puis les images classifiées sont analysées pour extraire le masque de changements [Blascke 2005, Stow 2010, Durieux et al. 2008, Hansen et Loveland 2012] ;

(c) la détection des changements des objets multitemporels/multi dates dans laquelle une méthode unique de segmentation est appliquée à l'ensemble des images multi dates mises en correspondance. Ces différentes images forment alors les différentes composantes d'une image de type vectorielle. Les techniques statistiques sont généralement appliquées à ce type de méthodes afin de construire le masque de changements [Deschée et al. 2005, Conchedda et al. 2008, Duveiller et al. 2008]. Malheureusement, pour analyser l'efficacité d'un algorithme à base d'objets, la plupart des chercheurs s'appuient sur le calcul de la matrice du taux d'erreur. Cette matrice comme il a été montré dans [Albrecht et al. 2010, Hernando et al. 2012] est un pilier de l'analyse niveau pixel et est totalement inadapté pour l'analyse à base d'objets qui combine informations spectrale, texturale et topologique à différents niveaux de résolution. De plus les algorithmes de segmentation utilisés dans cette famille de méthodes influent sur la forme des objets [Moller et al. 2007, Lein et al. 2012, Liu et Xia 2010]. Ces algorithmes utilisent généralement l'analyse multi résolution et sont limités dans la détermination du paramètre d'échelle qui se fait le plus souvent à l'aide d'algorithme essai-erreur [Dragut et al. 2010, Martha et al. 2011, Smith 2012].

Une autre piste intéressante développée avec les images THRS est l'utilisation des techniques de Data Mining. Ces techniques qui ont pour but d'extraire l'information implicitement cachée dans de sources d'informations assez riches ont été appliquées avec succès aux images basse, moyenne et haute résolution en y explorant les propriétés spectrales afin d'en extraire l'information cachée [Miller et Hahn 2001, Chelghoum et al. 2002]. Dans le cas de la détection des changements à partir de l'analyse à base d'objets, elles interviennent dans la phase de segmentation [Dos Santos, Silva et al. 2008, Boulila 2011] où elles produisent de meilleures performances que les méthodes de classification classiques. Elles améliorent également les stratégies de décision dans lesquelles elles remplacent avantageusement les techniques traditionnelles de seuillage [Otukey et Blaschke 2010, Vieira et al. 2012]. La

principale limitation de ces techniques de Data Mining est qu'elles nécessitent de disposer d'une base d'apprentissage, ce qui n'est pas toujours le cas.

Une alternative intéressante aux approches à base d'objets est d'étudier la possibilité d'étendre les méthodes traditionnelles aux images à Très Haute Résolution Spatiale en proposant des techniques capables de combiner les informations spectrales, spatiales et texturales de l'image. Ainsi des méthodes construisant des masques de changement à partir d'extraction d'attributs locaux tels que la texture ou les points et régions d'intérêt, suivie d'une classification des opérateurs de segmentation évolués issus de l'intelligence artificielle ont été proposées. Parmi celles-ci nous pouvons citer les méthodes à partir des arbres de décision [Lefèvre, Coppert et Hubert-Moy 2009], celles basées sur les approches à contrario [Flora et al. 2014], le classifieur SVM [Wu et al. 2012], les chaînes et les champs de Markov [Carincotte 2006, Bouyahia, Benyoussef et Derrode 2008, Voisin et al. 2013]. Parmi les méthodes précédemment citées, les approches markoviennes occupent une place importante puisqu'elles permettent une régularisation des processus de détection de changement par la prise en compte du contexte spatial et donc de la notion de voisinage d'un pixel [Zhong et Wang 2007, Benedek et Sziranyi 2009, Moser et al. 2011, Wang et al 2013, Sziranyi et Shadaydeh 2014, Hoberg et al. 2015, Benedek et al. 2015]. La principale limitation de ces approches est qu'elles sont adaptées aux cas de capteurs homogènes et à un type particulier d'applications, et elles ne peuvent être appliquées directement aux cas de capteurs hétérogènes.

Une revue plus complète de la littérature concernant les différentes méthodes de détection de changements dans les images de télédétection est disponible dans [Hussain et al. 2013 et Sagnika et al. 2014].

2.3. Détection des changements dans les images radars

Les radars imageurs utilisent des capteurs micro-ondes qui les rendent utilisables quelques soient les conditions atmosphérique et constituent une source d'information complémentaire aux imageurs optiques. Ces imageurs sont généralement affectés par du bruit multiplicatif. Par conséquent les techniques utilisées dans ce type d'images se sont développées en parallèle des techniques des imageurs optiques et en constituent une adaptation à la nature multiplicative du bruit associé. Ainsi les premières techniques furent basées sur l'utilisation de l'opérateur quotient [Bazi et al. 2005, Carincotte et al. 2006, Moser et Serpico 2006]. Elles étendent les

méthodes algébriques utilisées dans les images optiques en les adaptant au caractère multiplicatif du bruit présent dans ce type d'images. Les méthodes utilisées pour la détection des changements dans les images radar s'appuient généralement sur le log-ratio des images et diffèrent uniquement sur la façon de construire le masque de changement. La première approche consiste à rechercher un seuil de seuillage adaptatif en se basant sur l'hypothèse selon laquelle les pixels de la carte de changement sont spatialement indépendants et qu'ils sont les représentations de deux distributions gaussiennes selon qu'ils représentent ou pas un changement [Bruzzone et Prieto 2000]. Cette approche a été étendue par l'introduction de l'algorithme Espérance-maximisation (EM) comme méthode d'estimation des paramètres des distributions [Bazi et al. 2007, Celik 2010a]. Ces méthodes souffrent de deux limitations majeures que sont la complexité algorithmique de leur mise en œuvre et la diminution de leur performance lorsque le bruit multiplicatif devient important. La seconde approche consiste à utiliser les champs de Markov afin de tenir compte du contexte spatial de l'information [Kasetkasem et Varshney 2002]. L'hypothèse d'indépendance des pixels de « l'image différence » constitue sa principale limitation car dans la pratique cette hypothèse n'est pas vérifiée. La troisième approche qui produit un algorithme assez efficace consiste à combiner une approche globale et une approche locale [Celik 2009a]. En effet, « l'image différence » est décomposée en blocs non recouvrant puis dans chaque bloc des primitives sont extraites à partir de l'analyse en composantes principales. Par la suite, les pixels sont pris individuellement et projetés dans l'espace des vecteurs propres. Cette approche est limitée par le fait que la qualité de l'algorithme décroît lorsque les dépendances dans « l'image différence » sont non linéaires. Par la suite l'algorithme des k-moyennes est utilisé comme classifieur. La quatrième approche plus récente utilise l'analyse multirésolution par l'usage de la transformée en ondelettes [Bovolo et Bruzzone 2005, Celik 2009b, Celik et Ma 2010, Schmitt et al. 2010, Ajadi et al. 2016] pour éliminer l'effet du bruit multiplicatif. La transformée en ondelette non décimée [Celik et Ma 2011] a également été proposée. « L'image différence » est alors décomposée en sous bande d'ondelettes et un ensemble de descripteurs est extrait en chaque pixel. Le vecteur de changement est alors obtenu par utilisation de l'algorithme de k-moyennes comme classifieur. Malheureusement aucune des approches utilisées ne permet pas de résoudre tous les problèmes posés par l'utilisation des images radar. De plus, il n'existe pas de méthodes efficaces pour déterminer le niveau optimal de décomposition qui permettrait d'obtenir des résultats optimaux. Dans le cas des images radar à Très Haute Résolution Spatiale, les approches précédemment citées basés sur les pixels tombent en défaut car ce type d'images est caractérisé par une forte corrélation entre chaque pixel et ses voisins et une variation de la

texture des objets lorsqu'on change d'échelle de résolution. Les objets perdent alors de leur homogénéité à cause de la contribution du rayonnement électromagnétique des sous-objets qui le composent. Afin de prendre en compte ces spécificités seules les méthodes basées sur l'analyse multirésolution sont utilisées. Elles permettent à différentes échelles de faire ressortir les caractéristiques particulières d'un sous-objet qui compose l'objet étudié. Ainsi dans [Inglada et Mercier 2007] les auteurs proposent une analyse multirésolution à base d'ondelettes en utilisant le contexte spatial des pixels. Ainsi à chaque niveau de décomposition les primitives sont extraites en définissant une fenêtre centrée en chaque pixel. Les log-cumulants servent à déterminer les densités de probabilité des distributions marginales et la divergence de Kullback-Liebler est utilisée comme mesure de similarité. Cette méthode a introduit le concept de profil multi-échelle qui consiste à déterminer des indicateurs à chaque niveau de décomposition afin d'estimer la taille optimale de la fenêtre. Cette approche a été étendue dans [Bovolo et Bruzzone 2008] au calcul de la divergence de Kullback-Liebler dans le domaine temporel que spatial afin d'analyser les changements intervenus dans l'évolution de parcelles agricoles en Italie. La principale limitation de ces deux méthodes est qu'elles ne permettent que de détecter les changements n'affectant qu'un seul type d'objets et sont défailtantes dans le cas des images présentant plusieurs types de changements assez complexes.

2.4. Détection des changements à base de mesure de similarité

Dans ce paragraphe, nous aborderons une technique classique couramment rencontrée dans la littérature. Elle s'utilise aussi bien dans le contexte d'une détection en mode supervisé qu'en mode non supervisé. Elle est également applicable quel que soit le niveau de décision auquel on se situe. Le principe général repose sur deux étapes [Bruzzone et Bovolo 2012] :

- i) la construction d'un vecteur qui mesure la similarité éventuellement la dissimilarité entre objets présents dans l'image ;
- ii) le développement des algorithmes de décision suivant le score de ce vecteur en un objet.

Plus spécifiquement, la construction du vecteur de similarité prend en compte le développement d'un système de référencement géographique pour les deux images ou la série d'images afin de corriger les effets de la variabilité des conditions d'acquisition et de l'environnement. Cela permet également la définition des paramètres d'intérêt capable de

discriminer les changements intervenus dans les objets. La seconde étape s'appuie sur les méthodes de classification afin de construire le masque de changement. La construction du vecteur s'appuie sur des techniques allant de l'utilisation d'opérateurs algébriques aux méthodes statistiques.

Dans la suite de la thèse, nous allons nous intéresser aux méthodes statistiques [Alberga 2009, Hussain et al. 2013, Pillai et Vatsavai 2013, Sziranyi et Shadaydeh 2014a,]. Dans ce cas-là, l'image est décomposée en différentes fenêtres et le modèle est appliqué sur chaque fenêtre. La figure 2.1 illustre le principe dans le cas de la détection des changements entre une image optique et une image radar.

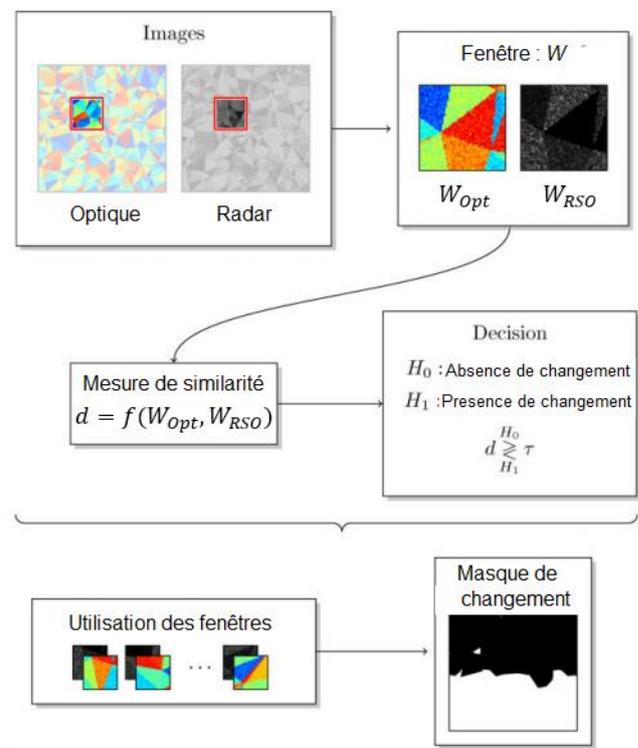


Figure 2. 1 Modèle de détections des changements à base d'analyse par fenêtres (source : [Prendes 2015])

Dans cet exemple, les fenêtres (W_{Opt}, W_{RSO}) sont indiquées par des zones rectangulaires mises en surbrillance. Sur un couple de fenêtres d'analyse (W_{Opt}, W_{RSO}) isolé, est calculé un score caractérisant la mesure de similarité entre les fenêtres des deux images. Le processus est appliqué sur l'ensemble des fenêtres afin de construire la matrice de similarité qui est ensuite affiné à l'aide d'un algorithme de décision afin de bâtir le masque de changement. Comme l'a démontré Bruzzone et Bovolo en 2012 [Bruzzone et Bovolo 2012], la principale difficulté de

ce processus est la construction de la mesure de similarité surtout lorsque les images sont des images à THRS. Dans la suite, nous allons passer en revue quelques techniques parmi les plus utilisées dans la littérature courante.

2.4.1. Coefficient de corrélation linéaire

Le coefficient de corrélation linéaire est la plus ancienne des mesures de similarité utilisée dans la détection des changements entre une paire d'images [Inglada et Giros 2004]. C'est un opérateur statistique qui mesure la dépendance linéaire entre deux distributions de probabilité X et Y . Plus précisément lorsqu'une même zone demeure inchangée entre deux images, la dépendance statistique entre les deux distributions de probabilité marginales représentant cette même zone est correctement modélisée par une dépendance linéaire. L'expression de ce coefficient est donné pour le cas continu par :

$$\rho = \frac{\int_{-\infty}^{+\infty} \int_{-\infty}^{+\infty} (x - \mu_X)(y - \mu_Y)p(x, y)dx dy}{\sqrt{\int_{-\infty}^{+\infty} (x - \mu_X)^2 p(x)dx} \sqrt{\int_{-\infty}^{+\infty} (Y - \mu_Y)^2 p(y)dy}} \quad (2.1)$$

avec μ_X et μ_Y les moyennes des distributions X et Y .

Dans le cas des images numériques, le coefficient de corrélation linéaire est donné par :

$$r_{XY} = \frac{\sum_{i=1}^N (x_i - m_X)(y_i - m_Y)}{\sqrt{\sum_{i=1}^N (x_i - m_X)^2} \sqrt{\sum_{i=1}^N (y_i - m_Y)^2}} \quad (2.2)$$

dans lequel $x = (x_1, x_2, \dots, x_N)$ et $y = (y_1, y_2, \dots, y_N)$ sont des réalisations respectives des processus aléatoires X et Y dont m_X et m_Y en sont les moyennes empiriques.

Le coefficient de corrélation linéaire est élevé lorsqu'il représente une zone inchangée et sa valeur est faible lorsque la zone a changé d'une image à l'autre. Même si le coefficient de corrélation linéaire a donné de bons résultats dans les premières applications de détection de changements [Inglada et Giros 2004] surtout lorsque les images présentent de grandes zones homogènes, il ne prend en compte qu'un seul type de dépendance à savoir la dépendance linéaire. Nous allons l'illustrer à l'aide des exemples suivants. La première paire d'images (figure 2.2) représente l'image d'une zone herbeuse d'une prairie (figure 2.2.a), tandis que la seconde image montre une texture aléatoire présentant la forêt qui a remplacé la prairie (figure 2.2.b). Les deux images de la figure 2.2 sont de taille 128×128 pixels et ont une résolution spatiale de 0.8 m.

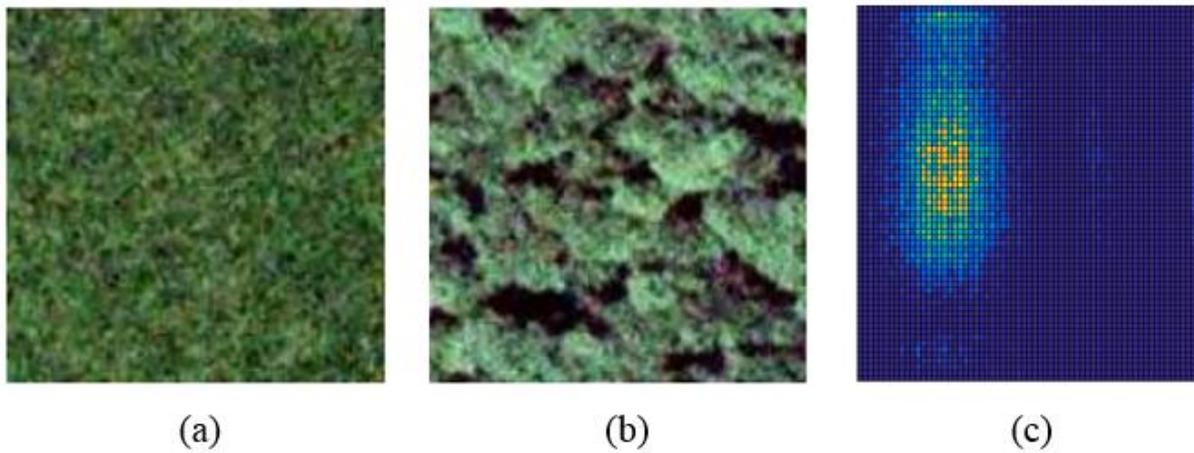


Figure 2. 2 Image présentant une zone de prairie changée (a) texture de prairie (b) texture de forêt (c) histogramme joint

Par la suite l’histogramme joint (figure 2.2.c) montre un pic qui traduit les changements dans un objet et ce dans la direction verticale. Le coefficient de corrélation global calculé est alors de -0.0226 qui est assez faible et qui est en concordance avec les résultats de l’histogramme joint. Dans le second exemple (Figure 2. 3), nous allons considérer l’image d’une même zone inchangée acquise par deux senseurs différents à savoir un optique (figure 2.3.a) et l’autre radar (figure 2.3.b). Les deux images ont été redimensionnées à la taille de 256×256 pixels. L’image optique a été acquise avec une résolution spatiale de 0.82m tandis que l’image radar à une résolution spatiale de 7.3 m .

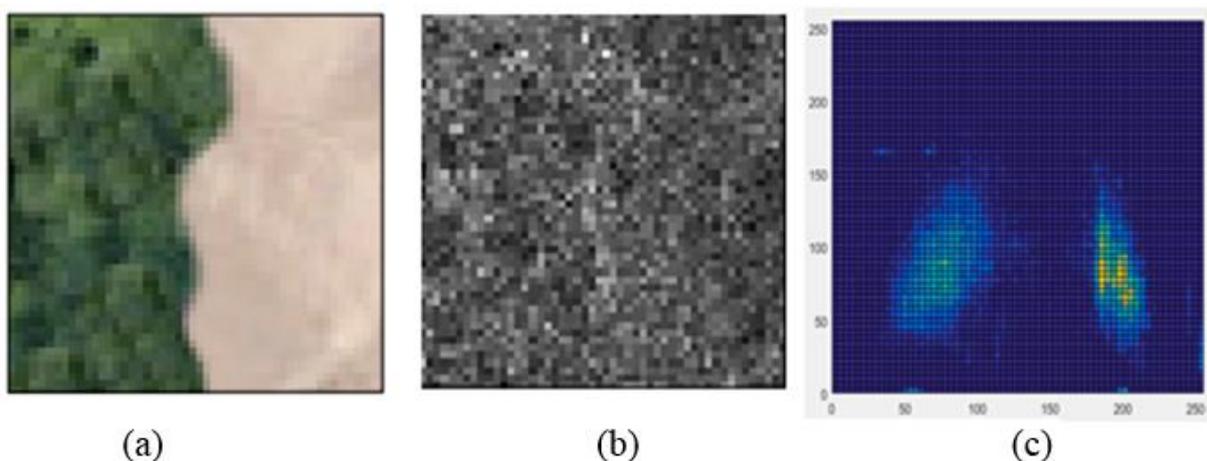


Figure 2. 3 Images d’une zone inchangée présentant deux objets distincts (a)Image optique présentant 2 objets (b) Image radar correspondante (c) histogramme joint

L’histogramme joint calculé par le logiciel MatLab (Figure 2.3.c) montre par la présence de deux pics que les images sont composées de deux zones. Les pics sont alignés dans la direction

horizontale, ce qui traduit une absence de changement au sein des deux images. Cependant les résultats obtenus par l'analyse du coefficient de corrélation linéaire global donnent une valeur de -0.1115 qui traduit que les deux images présentent de fortes différences. La figure 2.4 montre la matrice de corrélation linéaire obtenue pour des fenêtres de taille 10×10 pixels.



Figure 2. 4 Matrice de corrélation linéaire des deux images précédentes

Comme indiqué précédemment, l'analyse visuelle nous montre que le coefficient de corrélation linéaire n'arrive pas à distinguer les deux objets présents dans l'image. Les objets présents sont affectés par des variations internes.

2.4.2. Information mutuelle

Dans ce paragraphe, nous aborderons une autre technique classique couramment rencontrée dans la littérature qui est l'information mutuelle. Soient X et Y sont deux processus aléatoires continus, l'Information Mutuelle se définit de la façon suivante :

$$IM(X, Y) = \int_{-\infty}^{+\infty} \int_{-\infty}^{+\infty} p(x, y) \log \left(\frac{p(x, y)}{p(x)p(y)} \right) dx dy \quad (2.3)$$

dans laquelle $p(x)$ représente la fonction de densité de probabilité de la distribution marginale du processus X , $p(y)$ représente la fonction de densité de probabilité de la distribution marginale du processus Y , $p(x, y)$ représente la fonction de densité de probabilité de la loi jointe des processus X et Y . Dans le domaine discret, cette formule devient :

$$IM(X, Y) = \sum_{i=1}^N \sum_{j=1}^N \log(p_{i,j}) - \log(p_i) - \log(p_j) \quad (2.4)$$

Comme le montre la formule (2.4), en plus de la connaissance des f.d.p. des distributions marginales, elle dépend de l'estimation de la fonction de densité de probabilité jointe. L'estimation de cette f.d.p. jointe se fait soit à l'aide d'histogramme joint à deux dimensions, soit à l'aide des estimateurs à noyaux des densités de probabilité comme les fenêtres de Parzen et Rosenblatt.

Ainsi, deux images X et Y sont indépendantes lorsque l'information mutuelle $IM(X, Y) = 0$. Cela traduit alors le fait que les deux images sont totalement différentes. Au contraire, des valeurs différentes de zéro traduisent une certaine forme de corrélation entre ces deux images. La principale difficulté rencontrée est que cette f.d.p. jointe est fortement dépendante soit du nombre de bins utilisés dans le cas de l'histogramme joint, soit de la taille de la fenêtre dans le cas des méthodes à noyau [Kwak et Choi 2002]. Afin de pallier ces insuffisances, des chercheurs ont proposé l'estimation de la distribution de probabilité jointe à l'aide d'une approche paramétrique. Les paramètres des distributions sont estimés à partir d'un échantillonnage des données. Ainsi, la loi gamma bivariée a été utilisée comme mesure de similarité dans le cas de deux senseurs homogènes radar [Chatellain et al. 2007]. Plus récemment, dans le cas de l'analyse de deux images hétérogènes notamment dans le cas optique/radar, une généralisation du système de Pearson au cas multivarié [Chabert et Tournet 2011] a été utilisée afin d'estimer les paramètres de la distribution jointe.

Si nous reprenons le cas des deux images de la figure 2.2, nous obtenons un résultat de 0.3846 qui traduit une présence de changement puisque l'IM globale calculée est proche de 0. Dans le cas de deux images de la figure 2.3 l'information mutuelle globale est alors de 1.3007. Ce résultat implique que les deux images présentent une corrélation. La figure suivante (Figure 2.5) montre la matrice représentant l'information mutuelle entre les deux images de la figure 2.3 construite sur des voisinages locaux de taille 10×10 pixels comme précédemment.

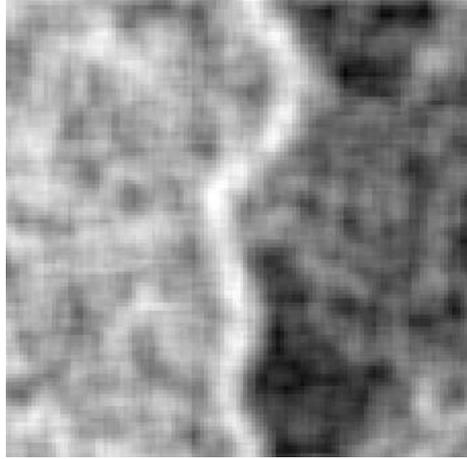


Figure 2. 5 Matrice IM des deux images optiques et radar d'une même zone

Comme pour le coefficient de corrélation linéaire, les résultats obtenus sont assez décevants puisqu'une analyse visuelle de l'image laisse entrevoir l'apparition d'une bande centrale dans l'image. L'intensité du niveau de gris assez élevée des pixels de cette bande centrale, traduit une zone inchangée. Il est à noter également la présence de deux zones latérales présentant des changements plus ou moins importants variant en sens inverse du niveau de l'intensité de gris. La zone latérale droite beaucoup plus sombre traduit une forte variation de changements dans cette zone. Alors que les deux images en réalité sont la représentation d'une même zone mais acquise avec des capteurs différents.

2.4.3. Divergence de Kullback-Liebler

Afin de résoudre les problèmes posés par l'estimation de la distribution de probabilité jointe, une alternative intéressante consiste à estimer la mesure de similarité à partir des distributions marginales elles-mêmes. Cette approche est réalisée au travers de l'utilisation de la divergence de Kullback-Liebler. Ainsi, si P et Q sont deux distributions de probabilité continues sur \mathbb{R} , alors la divergence de Kullback-Liebler est donnée par :

$$D_{KL}(P||Q) = \int_{-\infty}^{+\infty} p(x) \log \left(\frac{p(x)}{q(x)} \right) dx \quad (2.5)$$

Ainsi, par passage au domaine discret, si $x = (x_i)_{1 \leq i \leq N}$ est la réalisation du processus aléatoire $X = (X_i)_{1 \leq i \leq N}$ alors la divergence de Kullback-Liebler est donnée par :

$$D_{KL}(P||Q) = \sum_{i=1}^N p(x_i) \log \left(\frac{p(x_i)}{q(x_i)} \right) \quad (2.6)$$

La divergence de Kullback-Liebler n'est pas à proprement parlé une distance puisqu'elle n'est pas symétrique. Elle connaît un intérêt important pour la détection des changements dans les images de télédétection [Tian et al. 2014, Boudel et al. 2015] et plus particulièrement dans la détection des changements dans les images à THRS. Néanmoins, son usage est réservé au cas de senseurs homogènes. Par exemple, [Shgaier et Lepage 2015] analysent les dommages subis par les structures linéaires telles que les routes à l'aide d'images radars à très haute résolution spatiale. Cependant, très peu d'études lui sont consacrées dans le cas où l'on dispose de deux capteurs hétérogènes. Une avancée majeure est due aux travaux de recherche de Mercier et Moser en 2008 [Mercier et Moser 2008]. Ils proposent une version symétrique de la divergence de Kullback-Liebler de la forme :

$$D_{KL}(P||Q) = D_{KL}(Q||P) = D'_{KL}(P||Q) + D_{KL}(Q||P) \quad (2.7)$$

Ils s'appuient sur le fait que la divergence de Kullback-Liebler est faible dans une zone inchangée lorsque les deux capteurs sont homogènes puisque la distribution des pixels est alors similaire. Au contraire, lorsque les deux capteurs sont hétérogènes, la divergence de Kullback-Liebler devient importante puisque dans ce cas, la distribution des intensités des pixels diffère. Pour cela, ils proposent avant de calculer la divergence de Kullback-Liebler de transformer chacune des distributions associées à un capteur dans la distribution de l'autre capteur. La méthode d'apprentissage de cette transformation est effectuée grâce à l'usage de la copule appropriée sur des zones inchangées. Malheureusement, cette méthode ne peut être appliquée au cas de plus de deux images hétérogènes et nécessite la présence d'un photo-interprète afin d'estimer les zones d'apprentissage dans les images.

2.5. Conclusion

Dans ce chapitre consacré à l'état de l'art des méthodes de détection de changements, nous avons constaté que les méthodes les plus courantes de la littérature sont adaptées à des images issues de capteurs homogènes optique/optique ou radar/radar. Ces méthodes initialement basées sur la prise en compte individuelle des pixels ont évolué par la suite à une prise en compte simultanée de l'information spectrale et du contenu spatial des images pour tenir compte des particularités des images à Très Haute Résolution Spatiale. Cependant ces méthodes ne peuvent s'appliquer au cas de capteurs hétérogènes qui se développent de plus en plus. Face à ces limitations, la suite de ce manuscrit va proposer une méthode de détection des

changements adaptée aussi bien à la détection des changements entre des capteurs ou senseurs homogènes qu'aux capteurs hétérogènes dans le cas des images à Très Haute Résolution Spatiale. Le chapitre suivant introduira une nouvelle méthode d'extraction des primitives de textures qui va nous servir de brique élémentaire pour la construction de la nouvelle mesure de similarité.

Chapitre 3

Extraction des primitives de texture dans les images de télédétection

Sommaire

3.1. Introduction	47
3.2. Méthodes statistiques	49
3.2.1. Matrice de cooccurrence des niveaux de gris	49
3.2.2. Variogrammes	51
3.3. Méthodes basées sur un filtrage	53
3.3.1. Analyse de la texture par transformée de Fourier.....	53
3.3.2. Analyse de la texture par filtrage de Gabor.....	55
3.3.3. Analyse de la texture par transformée en ondelettes	57
3.4. Description des textures à l'aide des moments orthogonaux discrets de Tchebychev.....	59
3.4.1. Moments locaux de Tchebychev	60
3.4.2. Moments locaux de Tchebychev TRE invariants.....	64
3.5. Conclusion	69

3.1. Introduction

Dans le chapitre un, nous avons rappelé l'importance de la prise en compte d'informations supplémentaires notamment de l'attribut texture dans l'analyse des images à THRS. L'approche statistique de l'analyse des textures remontent aux travaux de Julesz [Julesz 1962] qui a montré que deux textures se distinguaient par leur statistiques d'ordre un et d'ordre deux, avant de trouver quelques années plus tard, des contre exemples [Julesz 1981]. Cela a conduit à la définition d'une nouvelle théorie de la perception humaine de la texture. Selon cette théorie, la perception humaine de la texture serait dès lors gouvernée par les statistiques d'ordre un de la distribution de primitives appelées textons. Cette notion de primitives se retrouve également dans la définition proposée par Haralick selon laquelle une texture peut être décrite par le nombre et le type de ses primitives ainsi que par l'organisation spatiale ou l'agencement de ces primitives [Haralick 1979]. D'autres études ont mis en évidence d'autres aspects de la perception humaine des textures, notamment les aspects multi fréquentiel [Campbell et Robson 1968], multi-échelles et multi orientation [De Valois et al. 1982]. L'étude des textures basée sur leur perception par la vision humaine a entraîné la naissance de différentes familles de méthodes organisées en quatre grandes catégories dans [Tuceyran et Jain 1998] :

- Les méthodes dites géométriques ou structurelles adaptées à l'analyse des macro-textures qui sont des textures constituées de motifs de base se répétant de façon quasi régulière dans des directions de l'espace (Figure 3.1.b). Ces méthodes s'appuient sur la recherche et la description exacte des motifs de bases appelés primitives, puis sur l'étude exacte de leurs règles de placement. On y retrouve les travaux d'Ojala et al. [Ojala et al. 1996] sur les motifs locaux binaires.

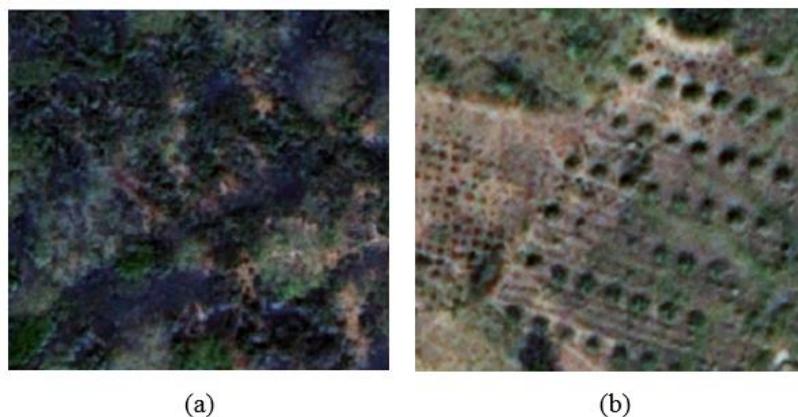


Figure 3. 1 Images optiques THRS de taille 512×512 pixels présentant des zones texturées (a) cacaoyère en forêt (micro-texture) (b) Cacaoyère en rang (macro-texture)

- Les méthodes basées sur le filtrage fréquentiel se réfèrent à une représentation fréquentielle et spatiale des données et font appel à des outils de filtrage tels que la transformée de Fourier bidimensionnelle, les filtres de Gabor [Manjunath et Ma 1996] et les décompositions en ondelettes [Mallat, 1989].
- Les méthodes basées sur des modèles cherchent à caractériser statistiquement l'image au moyen de modèles probabilistes en considérant la texture comme une réalisation d'un processus aléatoire. La description des propriétés de texture se ramène alors à l'identification ou à l'estimation des paramètres du modèle. On y retrouve les modèles markoviens qui sont couramment utilisés pour la modélisation de la texture, les modèles utilisant un filtre linéaire excité par un bruit blanc, avec comme cas particulier, les modèles autorégressifs (AR ou ARMA) dits « paramétriques », et d'autres modèles, comme les modèles de surfaces, ou le modèle de Wold et les modèles fractals.
- Les approches statistiques qui reposent sur l'analyse statistique de l'organisation spatiale des niveaux de gris ont été largement inspirées par les travaux de Julesz. Elles se sont révélées efficaces dans l'étude des micro-textures (Figure 3.1.a). Leur succès s'explique par le fait que l'œil humain ne prend en compte que les dépendances observées entre deux points proches. Ces méthodes incluent les matrices de cooccurrence des niveaux de gris [Haralick et al 1973], les fonctions d'autocorrélation et les variogrammes [Curran 1988].

Dans la suite de cette thèse, nous cherchons à connaître la distribution statistique de la texture qui nous servira à la construction d'une matrice de similarité. La modélisation statistique des textures consiste alors à estimer des statistiques d'ordre deux calculées selon une distance et une direction entre un pixel central et l'ensemble de ses voisins. Plusieurs approches ont été adoptées pour l'estimation de ses primitives. Parmi ces familles, nous allons passer en revue les plus utilisées en télédétection. La matrice de cooccurrence des niveaux de gris et le variogramme sont présentés dans la section 3.2. Les méthodes issues de l'analyse fréquentielle et spatiale que sont les transformées de Fourier, le filtrage de Gabor et la transformées en ondelettes seront étudiées dans la section 3.3. Dans la section 3.4, nous introduirons une nouvelle approche pour l'extraction des primitives de texture. Cette description des textures se fait par les moments orthogonaux discrets introduits par Munkundan [Munkundan 2001]. Nous montrerons par des exemples applicatifs l'apport de ce formalisme pour l'extraction des textures des images de télédétection. Nous terminerons ce chapitre par une conclusion en 3.5.

3.2. Méthodes statistiques

3.2.1. Matrice de cooccurrence des niveaux de gris

Les matrices de cooccurrence des niveaux de gris proposées par Haralick [Haralick et al. 1973] permettent d'estimer les caractéristiques d'une texture à une échelle locale. Cette matrice mesure le nombre d'occurrences de paires de niveaux de gris entre deux pixels séparés par une distance d dans une direction définie par un vecteur de déplacement (dx, dy) . L'expression de la matrice de cooccurrence des niveaux de gris pour une image de taille $N \times M$ est donné par :

$$MCNG_{dx,dy}(i, j) = \sum_{n=1}^N \sum_{m=1}^M \begin{cases} 1 & \text{si } l(n, m) = i \text{ et } l(n + dx, m + dy) = j \\ 0 & \text{sinon} \end{cases} \quad (3.1)$$

i et j représentent l'intensité du niveau de gris des pixels de référence et voisin, n et m les coordonnées du pixel de référence dans l'image. L'équation (3.1) montre que les entrées situées à proximité de la diagonale de la matrice de cooccurrence seront d'autant plus élevées que les valeurs de niveaux de gris de l'image sont proches ou similaires pour le déplacement considéré. A l'inverse, les entrées hors diagonale seront plus élevées pour des images dans lesquelles les niveaux de gris varient localement pour le déplacement considéré. Le contenu textural s'exprimera différemment en fonction de la distance et de l'orientation du déplacement considéré entre les paires de sites. En pratique, les entrées de la matrice de cooccurrence des niveaux de gris (MCNG) sont souvent normalisées en les divisant par le nombre de pixels (somme des entrées égale à 1) afin d'éliminer l'influence de la taille de l'image. En outre, la matrice de cooccurrence est généralement construite de manière symétrique en considérant la somme des entrées calculées pour deux déplacements de directions opposées [Haralick et al. 1973]. Ainsi, pour un déplacement horizontal sur une distance de 1, on intégrera simultanément les occurrences obtenues pour deux vecteurs de déplacement (dx, dy) égal à $(1,0)$ et à $(0,1)$.

Bien que les matrices de cooccurrence des niveaux de gris fournissent un ensemble assez riche de descripteurs, Haralick a proposé un ensemble de 14 descripteurs permettant de décrire l'information texturale contenue dans l'image dont les principaux sont résumés dans le tableau 3.1. Parmi ces descripteurs, 5 sont utilisés en pratique dans la littérature [Maillard 2003]. Ce sont le contraste, la corrélation, l'énergie, l'entropie et l'homogénéité. La principale limitation des méthodes de cooccurrence des niveaux de gris est liée au problème crucial du choix de la translation T (que l'on décompose en une direction et un déplacement d) et, surtout, à la

difficulté du traitement d'une masse importante d'information. Dans la pratique on privilégie quatre directions $\theta = 0^\circ, 45^\circ, 90^\circ, 135^\circ$ et deux déplacements $d = 1, 2$ après réduction du nombre de niveaux de gris à 16 ou 8. Afin de limiter le nombre d'information, il est d'usage courant de construire une seule matrice MCNG qui est la somme des différentes matrices de cooccurrence selon les angles et selon les directions précitées.

Tableau 3. 1 Formulation mathématique de quelques descripteurs d'Harralick

Descripteurs d'Harralick	Formulation mathématique
Energie	$\sum_i \sum_j P_{i,j}^2$
Entropie	$\sum_i \sum_j -P_{i,j} \log(P_{i,j})$
Contraste	$\sum_i \sum_j P_{i,j} (i - j)^2$
Homogénéité	$\sum_i \sum_j \frac{P_{i,j}}{1 + (i - j)^2}$
Corrélation	$\sum_i \sum_j P_{i,j} \left[\frac{(i - \mu_i)(j - \mu_j)}{\sigma_i \sigma_j} \right]$
Dissimilaire	$\sum_i \sum_j P_{i,j} i - j $

$P_{i,j}$ représente la probabilité d'occurrence d'une paire (i, j) des niveaux de gris dans la matrice de cooccurrence des niveaux de gris

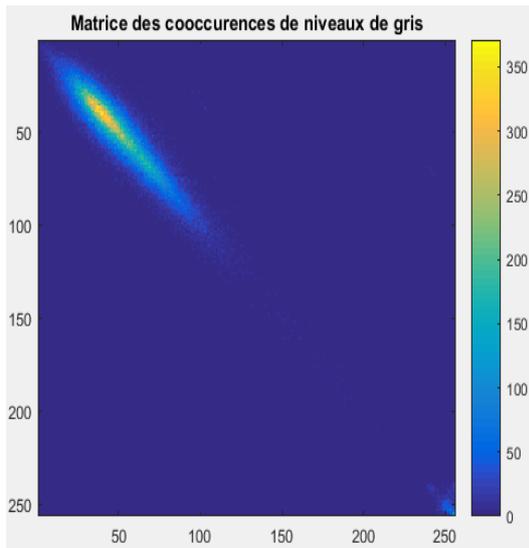
$\mu_i = \sum_i i P_{i,j}$ la moyenne des entrées normalisées pour le pixel de référence de niveau i

$\mu_j = \sum_j j P_{i,j}$ la moyenne des entrées normalisées pour le pixel de référence de niveau j

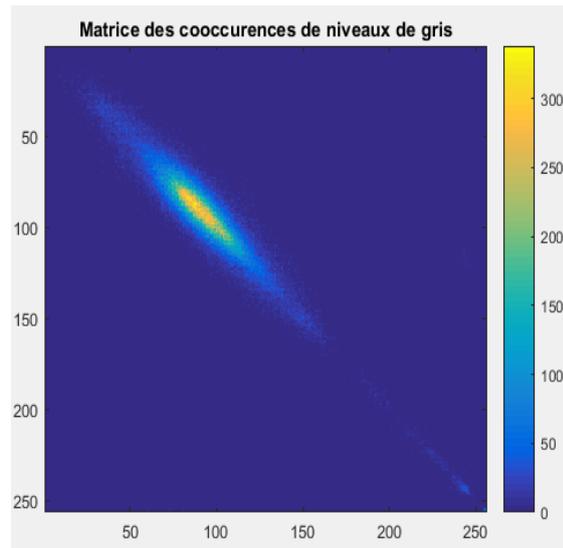
$\sigma_i = \sum_i P_{i,j} (i - \mu_i)^2$ l'écart-type des entrées normalisées pour le pixel de référence i

$\sigma_j = \sum_j P_{i,j} (j - \mu_j)^2$ l'écart-type des entrées normalisées pour le pixel de référence j

La figure 3.2 illustre la matrice MCNG obtenue dans le cas de nos textures de cacaoyère (Figure 3.1). Une étude détaillée des matrices de cooccurrence des niveaux de gris ainsi que l'essentiel de la littérature s'y afférant peut être trouvé dans [Regniers 2014].



(a)



(b)

Figure 3. 2 Exemple de matrices de cooccurrence de niveaux de gris. (a) texture uniforme (b) texture aléatoire (Paramètres de déplacement $(dx, dy)=(2,0)$, $\theta=0^\circ$)

3.2.2. Variogrammes

Le variogramme décrit les propriétés spatiales d'une image par estimation de la variance de la différence entre deux valeurs de paires de pixels [Curran 1988]. Le variogramme expérimental s'exprime mathématiquement comme l'espérance du carré de la différence de niveaux de gris entre deux pixels séparés d'une distance d de la manière suivante :

$$\gamma(d) = \frac{\sum_{(i,j) \in N(d)} |z_i - z_j|^2}{|N(d)|} \quad (3.2)$$

i et j sont des pixels adjacents séparés par une distance d , z_i et z_j les niveaux de gris et $N(d)$ l'ensemble des paires d'observation.

Traditionnellement, le variogramme est calculé pour un ensemble de déplacements et représenté sous la forme d'un graphe avec le déplacement d en abscisse et la semi-variance en ordonnée. Cette représentation graphique constitue le variogramme proprement dit. Les variogrammes peuvent être déterminés selon une seule direction ou en moyennant les variogrammes obtenus pour toutes les directions (variogramme omnidirectionnel). Dans ce dernier cas, le nombre de directions considérées peut varier d'une étude à l'autre (par exemple une variation de 0° à 150° par pas de 30° [Ruiz et al. 2011], une variation de 0° à 135° par pas de 45° [Maillard, 2003], une variation de 45° à 135° par pas de 45° [St-Onge et Cavayas, 1997]). L'approche omnidirectionnelle est surtout utile dans le cas des textures isotropes tandis que le choix d'une direction se révèle fructueuse dans le cas contraire afin de mieux conserver l'information. De ce modèle théorique peut être extrait un ensemble d'attributs caractérisant le comportement du modèle. La figure 3.3 montre l'exemple du variogramme construit à partir de l'image d'une texture caractérisant la forêt et le modèle théorique modélisant la dépendance spatiale (courbe en trait plein).

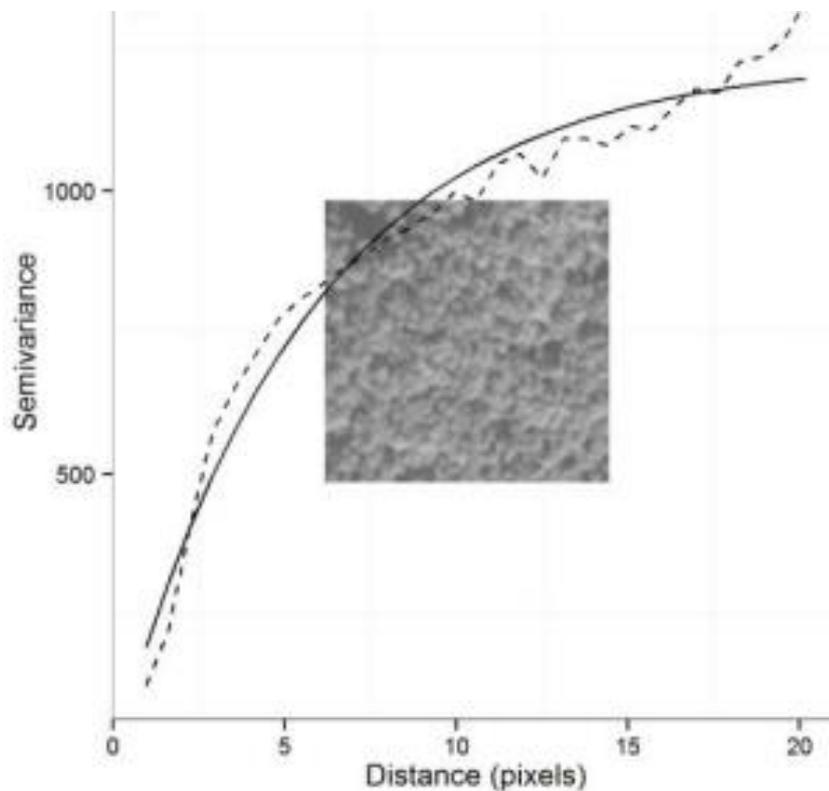


Figure 3.3 Exemples de semi-variogrammes – ligne pointillée = variogramme expérimental – ligne pleine = variogramme théorique estimée par modèle exponentiel (Source : [Regniers 2014])

L'application des variogrammes en télédétection à THRS se concentre principalement autour de deux thématiques : la classification ou la caractérisation du couvert forestier et la détection ou la classification de cultures agricoles. De manière générale, l'utilisation du variogramme peut être problématique lors de l'analyse de textures pour lesquelles l'ajustement d'un modèle paramétrique au variogramme expérimental est délicat.

3.3. Méthodes basées sur un filtrage

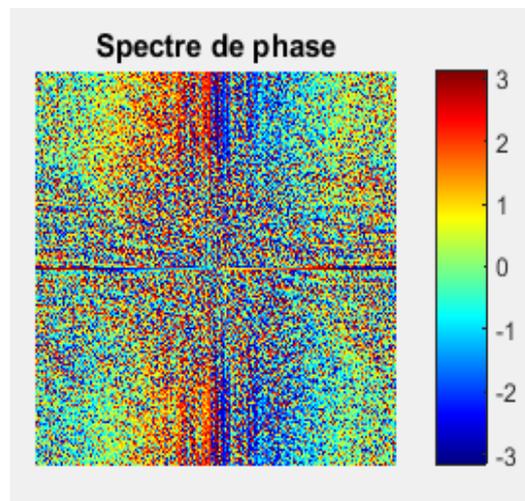
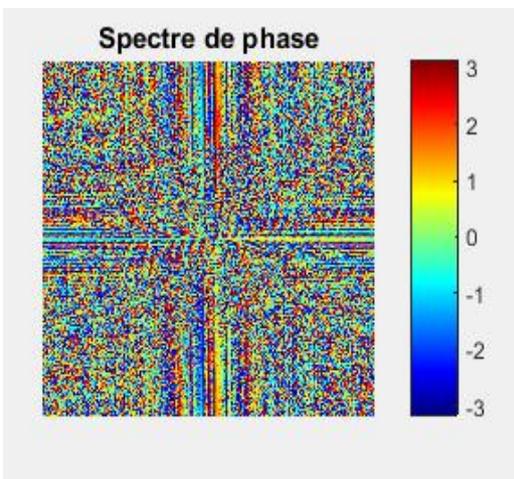
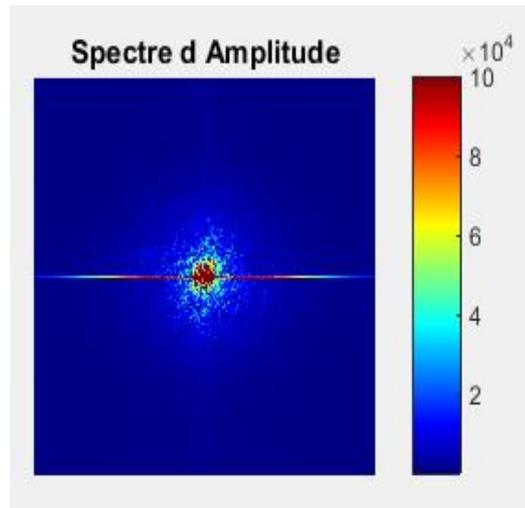
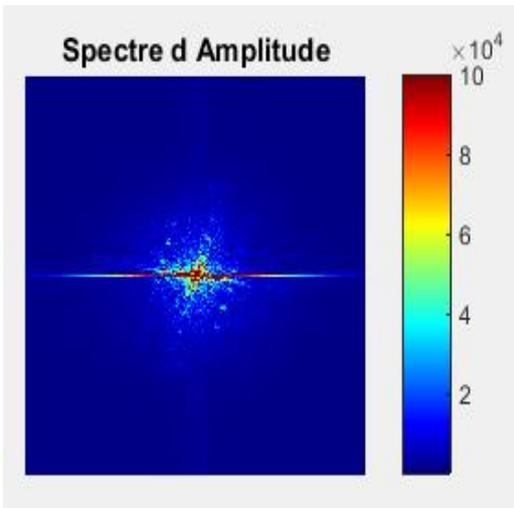
Les travaux sur l'analyse de la texture ont montré que celle-ci possède une composante fréquentielle. Les études basées sur l'analyse fréquentielle sont très nombreuses et nous allons voir en détail dans ce qui suit, les trois principales méthodes utilisées en télédétection.

3.3.1. Analyse de la texture par transformée de Fourier

Soit une image I de taille $N \times M$ dans le domaine spatial. Sa représentation dans le domaine fréquentiel est donnée par sa transformée de Fourier 2D définie par :

$$F(u, v) = \sum_{n=1}^N \sum_{m=1}^M I(n, m) \exp\left(-2j\pi \left(\frac{un}{N} + \frac{vm}{M}\right)\right) \quad (3.3)$$

dans laquelle u et v sont les fréquences spatiales. $F(u, v)$ est un nombre complexe et dans la pratique, on utilise plutôt le spectre d'amplitude ou le spectre de puissance qui sont respectivement l'intégrale du module et l'intégrale du carré du module sur toute l'image. Les coefficients obtenus traduisent les contributions aux différentes fréquences. Ainsi une texture lisse se caractérise par une concentration fréquentielle autour de l'origine alors que pour une texture rugueuse, les valeurs sont concentrées vers les hautes fréquences (Figure 3.4).



(a)

(b)

Figure 3. 4 Spectre d'amplitude et de phase de la transformée de Fourier des images de textures (a) Cacaoyère en rang (b) Cacaoyère en forêt

La transformée est aussi applicable dans un voisinage local. Par exemple, pour discriminer différents stades de développement de la mangrove, les auteurs de [Proisy et al. 2007]

déterminent sur des fenêtres de taille croissante un spectre radial en moyennant les coefficients du spectre de Fourier sur toutes les orientations. Une analyse en composantes principales permet ensuite d'identifier l'étendue des fréquences et la taille de fenêtre expliquant au mieux la variabilité. Ces critères sont alors utilisés pour cartographier la mangrove.

La principale limitation de la transformée de Fourier est que les fréquences sont localisées dans le spectre de fréquence, ce qui induit une perte de l'aspect variationnel dans l'espace. Le spectre ne permet donc pas de localiser spatialement les fréquences qu'il contient. Pour pallier cette insuffisance d'autres filtres ont été proposés comme les filtres de Gabor.

3.3.2. Analyse de la texture par filtrage de Gabor

Les filtres de Gabor permettent de filtrer le spectre de l'image selon des plages étroites de fréquence et d'orientation. Dans la pratique un filtre de Gabor est le produit d'un filtre gaussien modulé par une sinusoïde complexe. Du point de vue mathématique, un filtre de Gabor se formule comme suit :

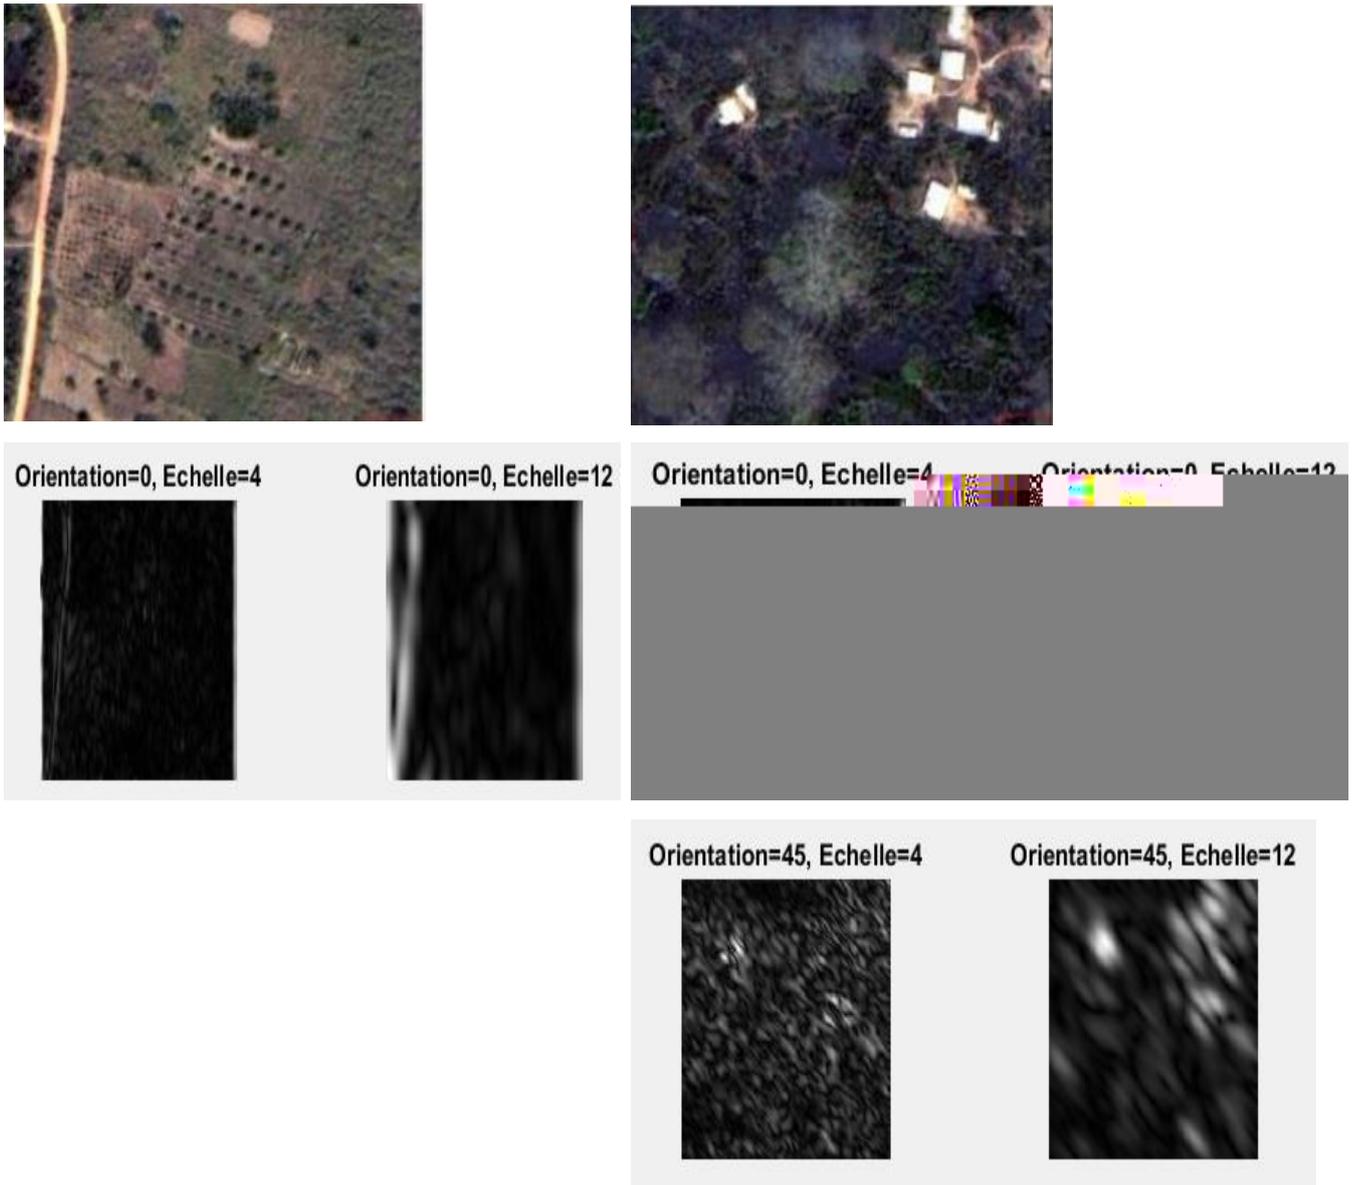
$$h(x, y) = \frac{1}{2\pi\sigma^2} \exp\left[-\frac{x^2 + y^2}{2\sigma^2}\right] \exp(2j\pi F(x\cos(\theta) + y\sin(\theta))) \quad (3.4)$$

σ^2 désigne l'étendue spatiale du filtre.

Dans le domaine fréquentiel, l'expression suivante des filtres de Gabor montre que ces filtres caractérisent une surface gaussienne de fréquence F dans la direction θ

$$H(u, v) = \exp(-2\pi^2\sigma^2((u - F\cos(\theta))^2 + (v - F\sin(\theta))^2)) \quad (3.5)$$

Dans l'analyse de texture, l'usage classique est de définir un banc de filtres centrés autour d'une fréquence F dans un ensemble de directions données de façon à couvrir tout le domaine fréquentiel. On observe l'ensemble des réponses données pour chaque pixel par chacun des filtres.



(a)

(b)

Figure 3. 5 Transformée de Gabor selon deux orientations et deux échelles des deux zones texturées (a) Cacaoyère en rang (b) Cacaoyère en forêt

Dans [Manjunath et Ma, 1996], les auteurs suggèrent de décomposer le spectre en plusieurs échelles et plusieurs orientations de telle sorte que chaque filtre couvre une portion distincte du demi-spectre en limitant les chevauchements et donc la redondance d'information. La moyenne et l'écart-type de la réponse obtenue pour chaque filtre sont ensuite calculés pour déterminer la signature texturale. La figure 3.5 présente l'image de la transformée de Gabor des images de la figure 3.1 pour différents angles d'orientation et d'échelles. La plupart des études qui ont suivi sont basées sur le même principe. Ainsi, les auteurs de [Li et al. 2010] proposent un algorithme de segmentation d'images à THRS basé sur la théorie des graphes et utilisant un attribut d'énergie de Gabor (plutôt que la moyenne et l'écart-type) comme critère de fusion des

régions. Dans une autre étude sur la détection des haies dans le paysage agricole [Aksoy et al. 2010], l'invariance à la rotation des attributs issus des filtres de Gabor est obtenue en conservant uniquement la réponse maximale pour toutes les orientations à une échelle donnée.

Il est à noter que l'aspect multi-échelles de la représentation par filtre de Gabor est particulièrement intéressant lorsque les structures physiques que l'on cherche à identifier dans l'image sont caractérisées par des objets ou des motifs de taille variable. De même, la configuration multi-orientations trouve tout son sens dans le cas d'analyse de textures anisotropes et permet de conserver une information de directionnalité dans la signature texturale. Malheureusement, les attributs texturaux extraits de ces filtres peuvent être corrélés en raison de la non-orthogonalité des filtres. Il peut dès lors s'avérer difficile de déterminer si une similarité observée entre échelles d'analyse est due aux propriétés de l'image ou à la redondance inhérente à la représentation. En outre, à chaque échelle d'application des filtres de Gabor, il faut modifier les paramètres définissant ces filtres.

3.3.3. Analyse de la texture par transformée en ondelettes

La transformée en ondelettes [Mallat 1989] est une méthode d'analyse fréquentielles tout comme la transformée de Fourier et les filtres de Gabor. Les méthodes de cette famille se basent sur l'extraction d'attributs à partir de l'image transformée par filtrage. Ces attributs sont ensuite exploités dans des algorithmes de classification ou de segmentation. Les ondelettes offrent un cadre d'analyse multi résolution uniforme car en une seule paramétrisation, nous obtenons une représentation de l'image à différents niveaux de résolution. Elles découpent l'image en sous bandes orthogonales limitant ainsi la redondance de l'information. Du point de vue mathématique si $f(x, y)$ désigne une image, alors sa transformée en ondelettes est donnée par :

$$g(u, s) = \iint f(x, y) \frac{1}{\sqrt{s}} \Psi\left(\frac{x-u}{s}, \frac{y-u}{s}\right) dx dy \quad (3.6)$$

u et s désignent respectivement le temps et la fréquence.

L'évolution de ces deux paramètres permet de construire une famille de fonctions créées par translation et changement d'échelle dérivée d'une fonction origine Ψ appelée ondelette mère. Les fonctions dérivées se définissent de la façon suivante :

$$\psi_{s,u} = \frac{1}{\sqrt{s}} \Psi\left(\frac{x-u}{s}\right) \quad (3.7)$$

En pratique, la transformée en ondelettes consiste à décomposer l'image en quatre sous-bandes LL, LH, HL et HH sous-échantillonnées d'un facteur 2 (ondelettes dyadiques) à chaque échelle de décomposition par application du produit de filtres passe-haut (H) et passe-bas (L) à une dimension. La sous-bande LL ou sous-bande d'approximation est une version moyennée de l'image d'origine alors que les sous-bandes HL, LH et HH ou sous-bandes de détails contiennent les hautes fréquences de l'image respectivement dans la direction de x (horizontale), dans la direction de y (verticale) ou dans les deux directions x et y (diagonale). Seules les sous-bandes de détails HL, LH et HH sont exploitées dans l'analyse texturale (Figure 3.6).

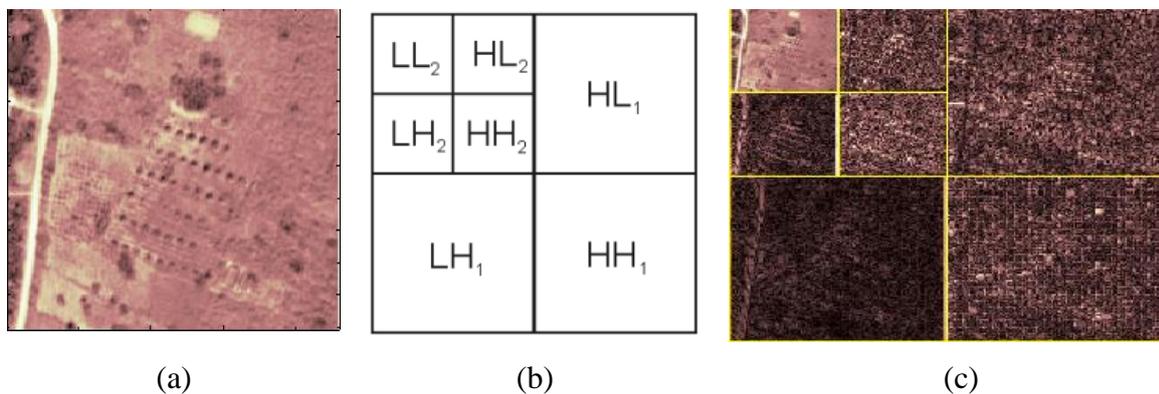


Figure 3. 6 Transformée en ondelettes de Daubechies à 2 niveaux de décompositions. (a) Image originale (b) Organisation des différents niveaux de décomposition (c) Résultat de la décomposition

Plusieurs familles d'ondelettes discrètes peuvent être utilisées en fonction de diverses formes de compromis entre régularité de la fonction et aspect plus ou moins compact de son support. La Transformée en Ondelettes Discrètes est limitée en deux points : la sélectivité directionnelle et l'invariance en translation [Selesnik et al. 2005]. Celle-ci ne permet en effet que trois directions d'analyse ce qui peut limiter la capacité de détection de certains contours. Ce constat a mené d'autres chercheurs à proposer de nouvelles formes de décomposition inspirées de la transformée en ondelettes discrètes comme la transformée par paquets d'ondelettes. Néanmoins, les sous-bandes obtenues par ces transformations ne sont plus orthogonales et l'information texturale extraite de ces sous-bandes peut être redondante. Plus récemment, des formes adaptatives de la transformée en ondelettes ont également été introduites pour l'analyse de textures orientées ou présentant des caractéristiques géométriques singulières non prises en compte par les transformées classiques (ridgelets [Do et Vetterli, 2003], curvelets [Arivazhagan et al. 2006], contourlets [Po et Do 2006], etc.). Afin de pallier les limitations de la transformée

en ondelettes discrètes, nous proposons d'utiliser pour nos images une méthode de décomposition indépendante de la direction d'observation des objets dans les images.

3.4. Description des textures à l'aide des moments orthogonaux discrets de Tchebychev

Les moments orthogonaux discrets de Tchebychev font partie de la famille des moments orthogonaux introduits par Hu [Hu 1962]. Les moments orthogonaux sont utilisés en reconnaissance de forme dans lesquels ils permettent de décrire les formes et présentent des propriétés d'invariance face aux transformations géométriques comme la translation, la rotation et le facteur d'échelle. De plus les moments orthogonaux présentent une grande robustesse face au bruit. Ils ont été introduits en 2001 par Munkundan [Munkundan 2001] à partir des polynômes de Tchebychev pour pallier les insuffisances de moments continus, notamment l'instabilité numérique causée par le passage de l'espace continu à un espace discret lors du calcul numérique de ces moments. Les moments orthogonaux discrets sont un outil essentiel en reconnaissance comme l'atteste l'abondante littérature qui lui est consacrée [Yap et al. 2003, Yap et al. 2007, Zhu et al. 2011, Zhu 2012, Mallahli et al. 2016]. En 2014, Munkundan [Munkundan 2014] a proposé d'utiliser les moments discrets orthogonaux de Tchebychev comme descripteurs de texture. Pour ce faire, il utilise un masque de convolution de taille 5×5 construits à partir des polynômes de Tchebychev de degré allant de 0 à 4. Ce masque est appliqué sur un voisinage centré de taille 5×5 pixels autour de chaque pixel de l'image. Les moments ainsi obtenus sont triés dans l'ordre croissant et l'index obtenu est identifié de façon unique compris entre 0 et 119 à l'aide d'un codage de Lehmer [Arndt 2011]. La figure 3.7 décrit le processus de construction de la matrice de texture par les moments locaux de Tchebychev proposé par Munkundan.

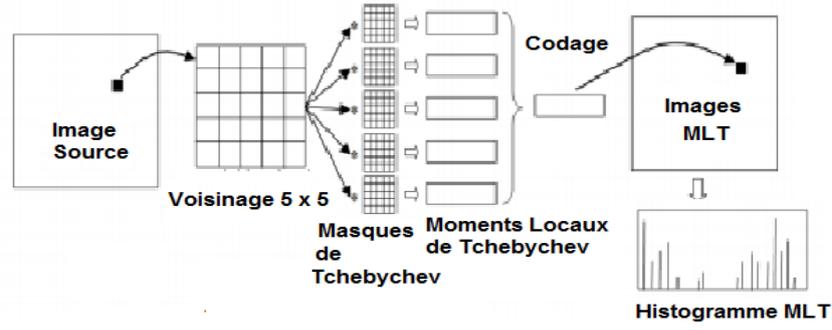


Figure 3. 7 Différentes étapes de la construction de la matrice de texture selon les moments discrets orthogonaux locaux de Tchebychev proposé par Munkundan

Cependant les moments utilisés ne sont pas invariants aux transformations géométriques et au facteur d'échelle. Une analyse efficace de la texture impose de prendre en compte un descripteur invariant à toute rotation d'objets présents dans l'image.

Pour la suite, nous allons utiliser le même principe que Munkundan pour obtenir nos descripteurs de texture, en remplaçant les polynômes de Tchebychev proposés dans [Munkundan 2014], par une extension de ces polynômes proposée par Yang en 2013 [Yang 2013].

3.4.1. Moments locaux de Tchebychev

Soit I une image donnée telle que $I(x,y)$ représente l'intensité du pixel aux coordonnées (x,y) . En chaque pixel (x,y) , nous allons considérer un voisinage de taille 5×5 centré autour du pixel (x,y) . Considérons le masque de convolution de Tchebychev M_{mn} d'ordre m, n avec $0 \leq m, n \leq 4$. Le moment de Tchebychev d'ordre m, n au pixel est défini par :

$$T_{mn}(x, y) = \sum_{i=0}^4 \sum_{j=0}^4 M_{mn}(i, j) I(x + i - 2, y + j - 2) \quad (3.8)$$

avec $m, n \in \{0,1,2,3,4\}$. Les masques de convolution de Tchebychev sont définis sur un voisinage de taille 5×5 par :

$$M_{mn}(x, y) = t_m(x)t_n(y) \text{ avec } m, n \in \{0,1,2,3,4\} \quad (3.9)$$

$t_n(x)$ sont les polynômes de Tchebychev unidimensionnels qui vérifient la propriété de récurrence suivante :

$$t_n(x) = A_n x t_{n-1}(x) + B_n t_{n-1}(x) + C_n t_{n-2}(x) \quad (3.10)$$

avec $x = 0, 1, 2, \dots, N - 1$ et $n = 2, 3, \dots, N - 1$

Les coefficients sont définis par :

$$A_n = \frac{2}{n} \sqrt{\frac{4n^2 - 1}{N^2 - n^2}} \quad (3.11)$$

$$B_n = \frac{(1 - N)}{n} \sqrt{\frac{4n^2 - 1}{N^2 - n^2}} \quad (3.12)$$

$$C_n = -\frac{(n - 1)}{n} \sqrt{\frac{2n + 1}{2N - 3}} \sqrt{\frac{N^2 - (n - 1)^2}{N^2 - n^2}} \quad (3.13)$$

avec

$$t_0(x) = \frac{1}{\sqrt{N}} \quad (3.14)$$

$$t_1(x) = (2x + 1 - N) \sqrt{\frac{4}{N(N^2 - 1)}} \quad (3.15)$$

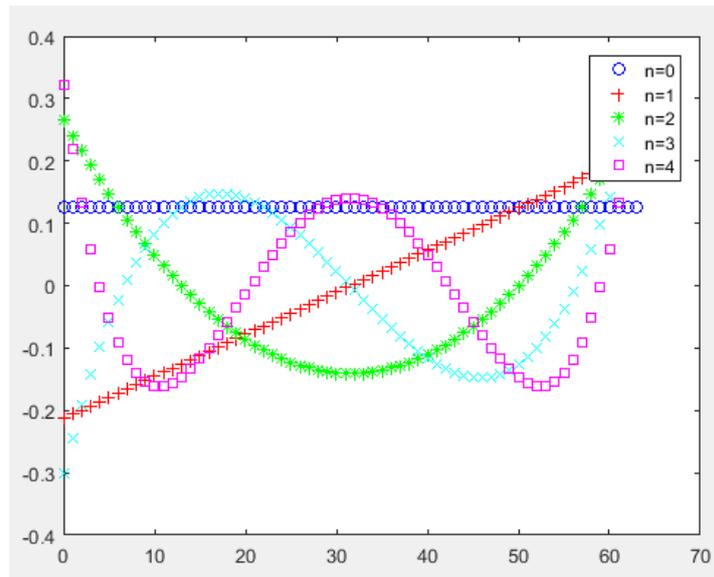


Figure 3. 8 Polynômes de Tchebychev pour $n=0, 1, 2, 3, 4$

Les noyaux de Tchebychev ainsi construits sont orthogonaux. Ils présentent un comportement oscillatoire sinusoïdal comme il est possible de l'observer sur la figure 3.8.

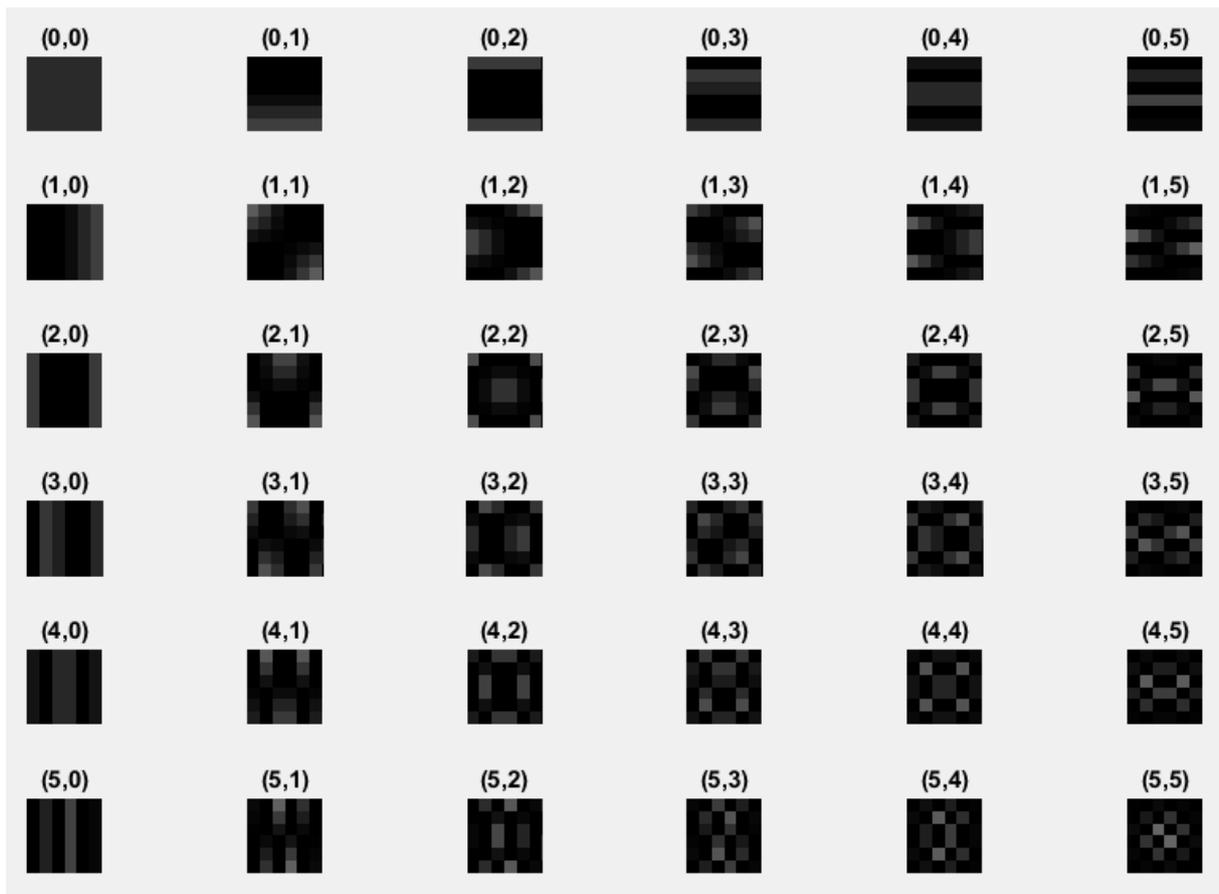


Figure 3. 9 Représentation spatiale des noyaux de Tchebychev pour $N=6$

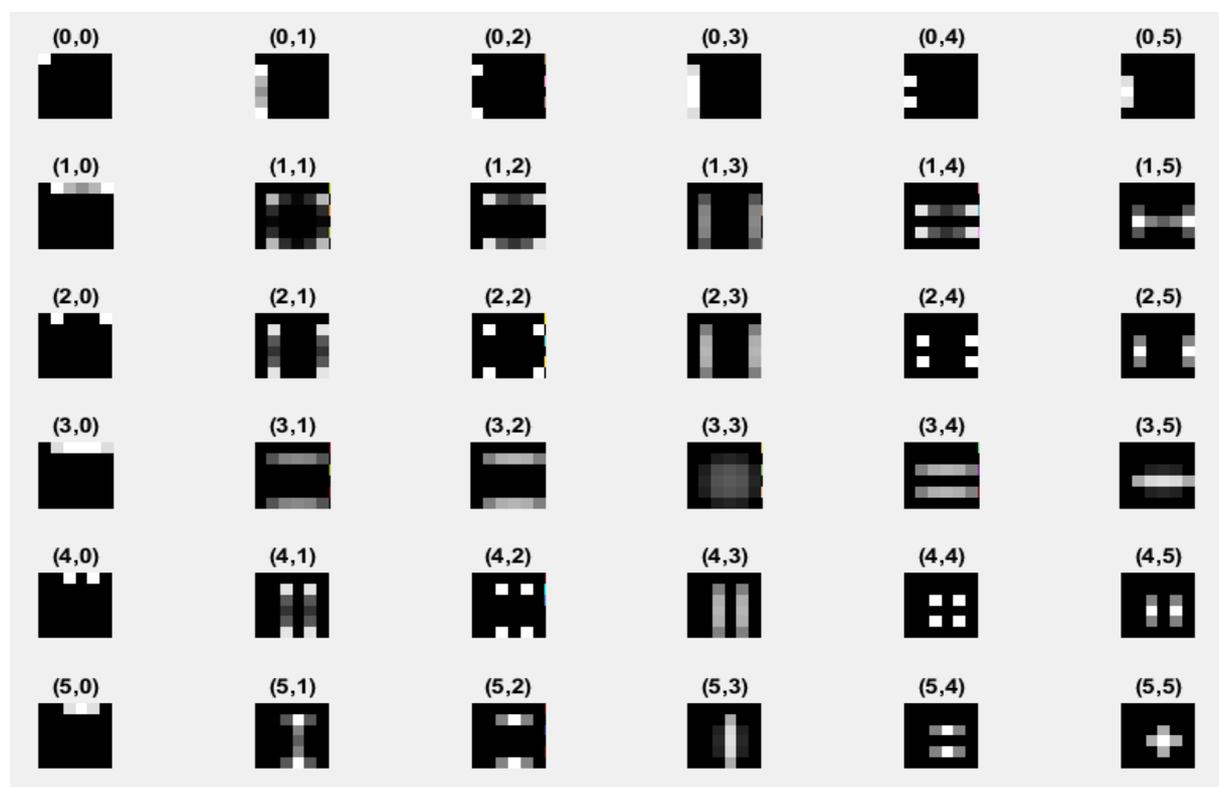


Figure 3. 10 Représentation du module du spectre des noyaux de Tchebychev pour $N=6$

Les auteurs de [Marcos et Cristobal 2013] ont montré que les moments orthogonaux discretes de Tchebychev peuvent servir de base à la construction d'un vecteur de signature suffisamment discriminant et robuste aux bruits. C'est cette approche que nous avons retenue pour projeter nos images dans l'espace des descripteurs et construire notre mesure de similarité. La figure suivante illustre le principe adopté.

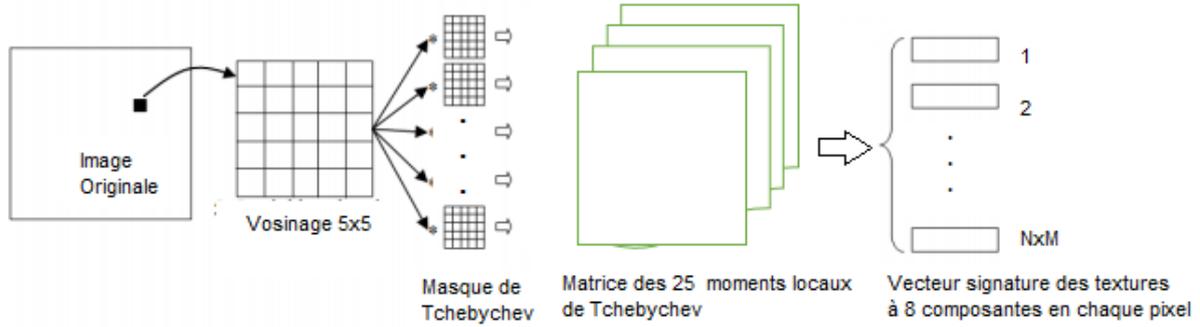


Figure 3. 11 Processus de construction du vecteur de descripteurs

Marcos et Cristobal ont montré que l'amplitude des moments de Tchebychev $T_{mn}(x, y)$ d'une image $I(x, y)$ obtenus selon l'équation (3.8) représente la corrélation entre l'image et les $M_{mn}(x, y)$ différents noyaux de Tchebychev d'ordre $s = m + n$. Il en résulte que plus l'image $I(x, y)$ et le noyau de Tchebychev $M_{mn}(x, y)$ varient de la même manière dans une direction donnée, plus l'amplitude est élevée. Une autre caractéristique importante des noyaux de Tchebychev est qu'une représentation spatiale à 2 dimensions d'un noyau de Tchebychev d'ordre $s=m+n$ (Figure 3.9) donne un même motif contenu dans l'image selon des impulsions positives et négatives. Et l'orientation de ce motif varie d'un moment à un autre. Cependant, deux moments de même ordre représentent un même motif dans différentes directions.

Une analyse fréquentielle montre que le moment d'ordre $s=m+n$, $T_{mn}(x, y)$, peut être vu comme la réponse du filtrage par un masque $M_{mn}(x, y)$ de l'image $I(x, y)$. Cela se traduit par la relation suivante :

$$T_{mn}(x, y) = (-1)^{n+m} (M_{mn} * I)(0,0) = (-1)^{n+m} g_{mn} (0,0) \quad (3.16)$$

Par la suite, nous avons par calcul de la transformée de Fourier inverse :

$$g_{pq}(x, y) = FFT^{-1}\{G_{pq}(u, v)\} \quad (3.17)$$

$$g_{pq}(x, y) = K \sum_{u=0}^{N-1} \sum_{v=0}^{N-1} \hat{I}(u, v) \hat{M}_{pq}(u, v) \exp\left(-2j\pi \left(\frac{ux + vy}{N}\right)\right) \quad (3.18)$$

et en posant $(x, y) = (0, 0)$ dans l'équation (3.18)

$$T_{pq} = (-1)^{p+q} K \sum_{u=0}^{N-1} \sum_{v=0}^{N-1} I(u, v) \hat{M}_{pq}(u, v) \quad (3.19)$$

$$T_{pq} = (-1)^{p+q} K \sum_{u=0}^{N-1} \sum_{v=0}^{N-1} |G_{pq}(u, v)| \cos[\varphi_{pq}(u, v)] \quad (3.20)$$

Le résultat se déduit de la symétrie des noyaux de Tchebychev. De l'équation (3.20), il est facile de constater que l'amplitude des moments de Tchebychev est influencé par deux paramètres : l'angle d'orientation entre la fonction image et le noyau de Tchebychev et la fréquence de concentration de l'énergie contenue dans l'image. L'équation 3.20 montre que le spectre de noyau de Tchebychev influe sur les fréquences participant à la construction du moment. De plus, les noyaux de même ordre présentent des spectres concentrés autour des mêmes fréquences mais dans des directions différentes (Figure 3.10). Par la suite, nous allons utiliser comme vecteur de signature les amplitudes des différents moments à différents ordres. Ainsi nous allons construire le vecteur signature des textures $M(s)$ de la façon suivante :

$$M(s) = \sum_{p+q=s} |T_{pq}^{<trs>}| \text{ avec } s = \{0, 1, 2, \dots, 2N - 1\} \text{ et } 0 \leq p, q \leq N - 1 \quad (3.21)$$

Le vecteur $M(s)$ ainsi construit peut être vu comme la résultante d'un filtrage selon un filtre passe bande autour de fréquences déterminées par l'ensemble des noyaux M_{mn} avec $m + n = s$. Le vecteur ainsi obtenu fournit les informations sur les propriétés des textures contenues dans l'image et de ce point de vue est considéré comme la signature texturale de l'image. Cependant même si ces moments ont montré leur robustesse face aux rotations des formes géométriques dans les images, ils ne sont pas invariants aux translations et au passage à l'échelle [Marcos et Cristobal 2013].

3.4.2. Moments locaux de Tchebychev TRE invariants

Les moments précédemment obtenus ne sont pas invariants aux transformations géométriques telles que la translation la rotation ou le facteur d'échelle. Cela pose un problème car par exemple un changement d'orientation de la texture d'un labour dans une parcelle agricole pourra alors à partir de ces moments être identifié comme un changement de texture. Pour pallier de telles limitations, il nous faut trouver des moments invariants par rotation. Nous allons donc utiliser la transformation proposée par Yang [Yang 2013] pour construire une famille de moments invariants par translation, rotation et facteur d'échelle appelés moments de Tchebychev TRE invariants. L'algorithme proposé par Yang tire son avantage de ce que ces

nouveaux moments ne nécessitent pas de transformation particulière de l'image originale contrairement aux algorithmes précédemment utilisés. En nous ramenant aux hypothèses précédentes si $I(x, y)$ représente l'intensité d'un pixel de coordonnées (x, y) et si nous posons $S_2(N) = \{(x, y) | x, y = 0, 1, 2, \dots, N - 1\}$ alors, nous obtenons des moments qui sont un cas particuliers des moments affines de Tchebychev et qui sont définis par :

$$T_{mn}^{<am>} = |J| \sum_{x=0}^{N_0-1} \sum_{y=0}^{N_0-1} t_m(a_1x + a_2y + a_3) t_n(b_1x + b_2y + b_3) f(x, y) \quad (3.22)$$

avec $a_1, a_2, a_3, b_1, b_2, b_3 \in R$ et $n, m = 0, 1, 2, \dots, \min(N_0 - 1, N_s - 1)$

J est le jacobien de la matrice $\begin{pmatrix} a_1 & a_2 \\ b_1 & b_2 \end{pmatrix}$ tel que $|J| \neq 0$.

Le choix adéquat des coefficients permet de construire les moments invariants par TRE. Par la suite d'après [Yang 2013], si $I_{mn}^{<am>}$ est la transformée affine des moments de Tchebychev qui vérifie les propriétés suivantes :

$$I_{00}^{<am>} = \Omega_0 N_s \quad (3.23)$$

$$I_{10}^{<am>} = 0 = I_{01}^{<am>} \quad (3.24)$$

$$I_{11}^{<am>} = 0 \quad (3.25)$$

$$I_{20}^{<am>} > I_{02}^{<am>} \quad (3.26)$$

alors

$$\begin{aligned} I_{mn}^{<am>} &= \omega^2 \sum_{x=0}^{N_0-1} \sum_{y=0}^{N_0-1} t_m \left(\omega \cos(\theta)(x - \bar{x}) + \omega \sin(\theta)(y - \bar{y}) + \frac{N_s - 1}{2} \right) \\ &\quad \times t_n \left(-\omega \sin(\theta)(x - \bar{x}) + \omega \cos(\theta)(y - \bar{y}) + \frac{N_s - 1}{2} \right) \\ &\quad \times f(x, y) \end{aligned} \quad (3.27)$$

avec $n, m = 0, 1, 2, \dots, \min(N_0 - 1, N_s - 1)$

$$\omega = \sqrt{\frac{\Omega_0 N_s^2}{T_{00} N_0}} \quad (3.28)$$

et

$$\theta = \frac{1}{2} \tan^{-1} \left\{ \frac{2 \left(\frac{N_0 - 1}{2} - \bar{x} \right) \left(\frac{N_0 - 1}{2} - \bar{y} \right) A_1 T_{00} + 2 \left(\frac{N_0 - 1}{2} - \bar{x} \right) T_{01} + 2 \left(\frac{N_0 - 1}{2} - \bar{y} \right) T_{10} + \frac{2T_{11}}{A_1}}{A_1 \left[\left(\frac{N_0 - 1}{2} - \bar{x} \right)^2 - \left(\frac{N_0 - 1}{2} - \bar{y} \right)^2 \right] T_{00} - 2 \left(\frac{N_0 - 1}{2} - \bar{x} \right) T_{10} + 2 \left(\frac{N_0 - 1}{2} - \bar{y} \right) T_{01} + \frac{T_{20}}{A_2} - \frac{T_{02}}{A_2}} \right\} \quad (3.29)$$

\bar{x} et \bar{y} sont les centroides de l'image originale calculés en fonction des moments géométriques

$$\bar{x} = \frac{m_{1,0}}{m_{0,0}}, \bar{y} = \frac{m_{0,1}}{m_{0,0}} \quad (3.30)$$

avec

$m_{p,q} = \int_{-\infty}^{+\infty} \int_{-\infty}^{+\infty} x^p y^q f(x,y) dx dy$ les moments géométriques d'ordre $p + q$. Dans le domaine discret, ces moments géométriques sont définis par

$$m_{p,q} = \frac{1}{NM} \sum_{x=1}^N \sum_{y=1}^M x^p y^q I(x,y) \quad (3.31)$$

I est une image de dimension $M \times N$ et $I(x,y)$ représente l'intensité du pixel de coordonnées (x,y) . Il en résulte que si nous considérons comme dans [Munkundan 2014] un voisinage V_{xy} de taille 5×5 centré autour du pixel de coordonnées (x,y) , nous obtenons :

$$I_{n,m}^{(trs)}(x,y) = \omega^2 \sum_{k=0}^{n+m} \sum_{j=0}^{n+m-k} \lambda_{n,m,k,j}^{(trs)} M_{k,j}(x,y) \quad (3.32)$$

Les moments $M_{k,j}(x,y)$ sont calculés selon l'équation de Munkundan (cf. équation 3.8), et

$$\lambda_{n,m,k,j}^{(trs)} = \lambda_{n,m,j,k} \left(\begin{array}{c} \omega \cos(\theta), \omega \sin(\theta) \\ -\omega \bar{x} \cos(\theta) - \omega \bar{y} \sin(\theta) + \frac{N_s - 1}{2} + w_x \\ -\omega \sin(\theta), \omega \cos(\theta) \\ \omega \bar{x} \sin(\theta) - \omega \bar{y} \cos(\theta) + \frac{N_s - 1}{2} + w_y \end{array} \middle| N_0, N_s \right) \quad (3.33)$$

Les paramètres ω et θ seront estimés selon les équations (3.27) et (3.28).

N_0 et N_s représentent les degrés des polynômes de Tchebychev. Dans notre cas, ces deux valeurs seront égales entre elles et vaudront 5. Le calcul explicite des coefficients $\lambda_{n,m,k,j}^{(trs)}$ est

donné en Annexe A. La figure 3.12 montre un exemple d'application des moments de Tchebychev TRE invariants sur des images binaires du chiffre '3' et de la lettre 'a'. Les images ont une taille de 60×60 pixels, et les images seront transformées par des rotations d'angle compris entre 0° et 359° ainsi qu'une translation et en échelle.

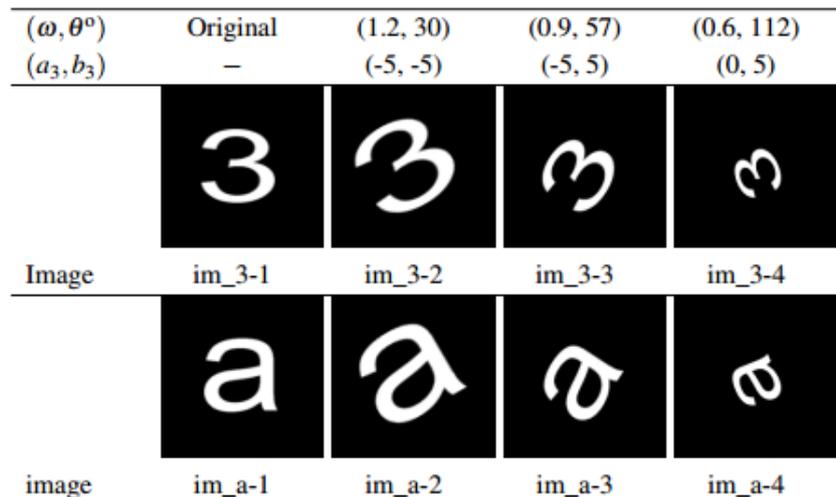


Figure 3. 12 Images binaires transformées par Translation rotation et facteur d'échelle

Tableau 3. 2 Résultats des différents moments de Tchebychev TRE invariants

Image	$I_{0,0}^{<TRE>}$	$I_{2,0}^{<TRE>}$	$I_{1,1}^{<TRE>}$	$I_{0,2}^{<TRE>}$	$I_{3,0}^{<TRE>}$	$I_{2,1}^{<TRE>}$	$I_{1,2}^{<TRE>}$	$I_{0,3}^{<TRE>}$
Im_3-1	20.000	-15.131	0.000	-17.002	0.531	-0.745	-0.325	-1.319
Im_3-2	20.000	-15.132	0.000	-17.003	0.530	-0.746	-0.326	-1.319
Im_3-3	20.000	-15.132	0.000	-17.003	0.530	-0.746	-0.326	-1.319
Im_3-4	20.000	-15.136	0.000	-17.008	0.533	-0.744	-0.323	-1.314
Ecart-Type (%)	0.000	0.013	0.000	0.032	0.488	0.226	0.283	0.420
Im_a-1	20.000	-17.632	0.000	-18.071	0.126	0.356	0.071	0.008
Im_a-2	20.000	-17.633	0.000	-18.071	0.126	0.356	0.071	0.008
Im_a-3	20.000	-17.633	0.000	-18.071	0.125	0.356	0.071	0.008
Im_a-4	20.000	-17.633	0.000	-18.073	0.124	0.354	0.072	0.008
Ecart-Type (%)	20.000	0.022	0.000	0.023	1.959	0.351	0.070	0.054

Les résultats regroupés dans le tableau 3.2 montrent l'efficacité de l'algorithme proposé. Une analyse de l'écart-type moyen montre que l'algorithme est relativement stable quel que soit les transformations subies par les images. Les figures 3.13 et 3.14 illustrent les attributs de texture d'une image de zone péri-urbaine acquise par le satellite IKONOS.

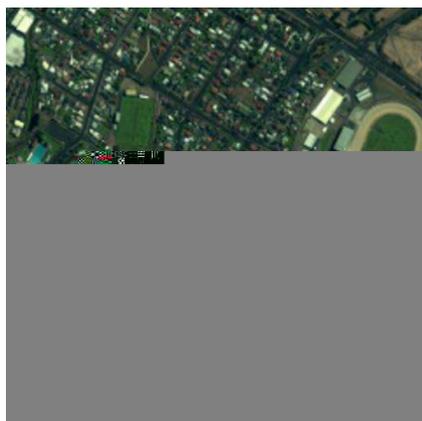


Figure 3. 13 Image d'une zone péri-urbaine acquise par IKONOS

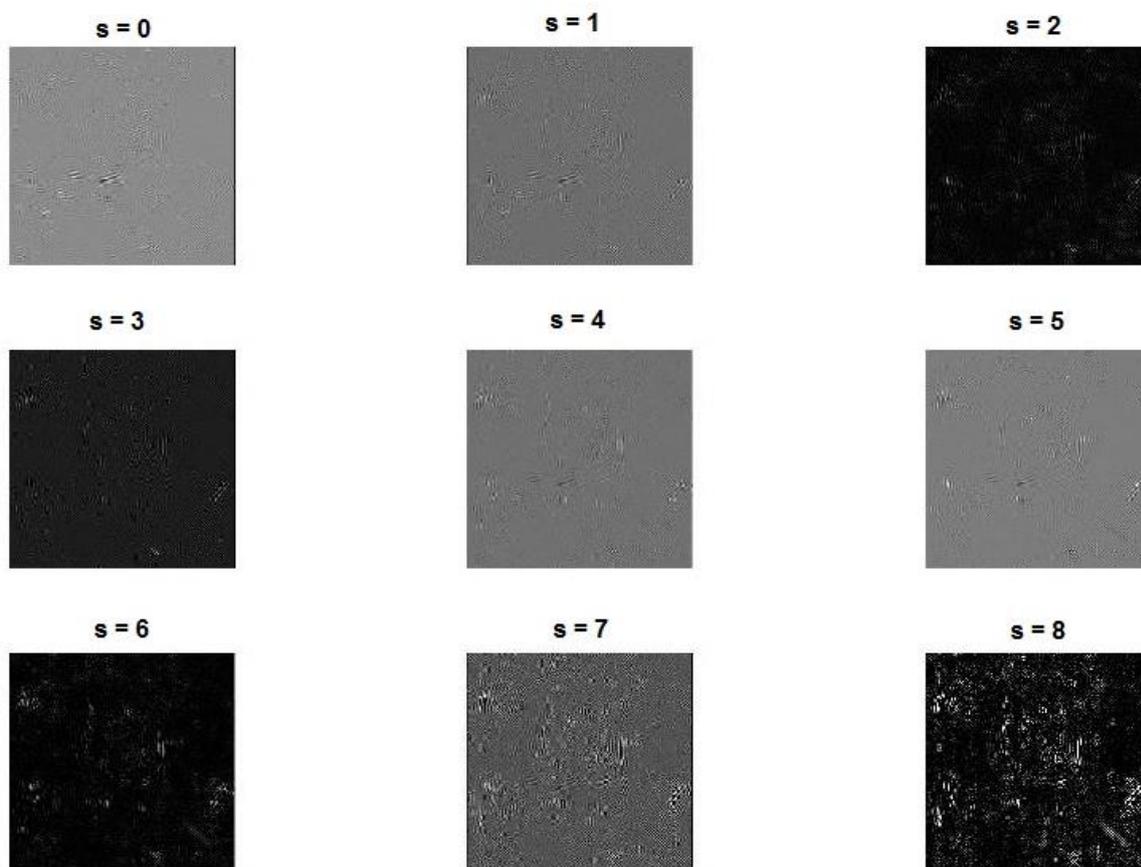


Figure 3. 14 Matrice des attributs de textures extraits à partir des moments locaux de Tchebychev

Comme indiqué dans les paragraphes précédents, les attributs de texture extraits sont fonction de la fréquence et de la direction de variation des intensités des niveaux de gris de l'image et du masque de Tchebychev. Les variations les plus importantes ont lieu dans des directions diagonales. Les matrices d'ordre élevé présentent le plus de variations puisque les

masques associés (Figure 3.9) sont ceux qui présentent le plus de variations. L'ensemble des matrices ainsi obtenues permet de caractériser une texture de façon unique et sans ambiguïté.

3.5. Conclusion

Nous avons pu constater que dans le cas des images à THRS, la seule modélisation des intensités des pixels était insuffisante pour permettre une analyse efficace et que la prise en compte des attributs texturaux présents dans les images améliorerait l'analyse statistique de ce type d'images. Dans ce chapitre, nous avons passé en revue les différentes techniques d'extraction des propriétés des textures, puis nous avons proposé un nouveau modèle d'extraction de ces attributs texturaux à partir des moments locaux de Tchebychev. Ces attributs présentent la particularité d'être invariants au facteur d'échelle et à toute transformation géométrique subie par l'image. Cela nous permet alors de distinguer sans ambiguïté une texture qui a changé d'orientation comme par exemple le labour d'un champ qui a changé d'orientation d'une image à une autre. Ces descripteurs nous permettent d'obtenir une signature texturale qui nous servira de base à la construction de notre mesure de similarité dans le prochain chapitre.

Chapitre 4

Nouvelle mesure de similarité pour la détection des changements dans les images à THRS

Sommaire

4.1. Introduction	71
4.2. Segmentation en superpixels	71
4.2.1. Décomposition en superpixels.....	72
4.2.2. L'algorithme SLIC	73
4.3. Estimation de la mesure de similarité.....	74
4.3.1. Modélisation statistique des distributions de probabilité marginales	74
4.3.1.1. Images optiques	75
4.3.1.2. Les images radar à synthèse d'ouverture (RSO)	76
4.3.2. Distribution jointe.....	77
4.3.2.1. Zones homogènes	77
4.3.2.2. Zone hétérogène	78
4.3.2.3. Nouvelle mesure de similarité	79
4.4. Estimation des paramètres	82
4.4.1. Sélection de la meilleure copule.....	82
4.4.2. Estimation des paramètres du mélange des densités	85
4.5. Analyse des résultats sur des données de synthèse	87
4.6. Conclusion	90

4.1. Introduction

Dans ce chapitre, nous utilisons les attributs de texture extraits à partir de la méthode des moments locaux discrets de Tchebychev TRE invariants afin de construire une nouvelle mesure de similarité basée sur une représentation statistique de leurs contenus. Le schéma proposé pour la définition de cette nouvelle mesure de similarité, respecte les principes de base de l'analyse des images de télédétection par l'approche objet à savoir, une segmentation des images sources suivie d'une étude comparative des résultats de la segmentation afin d'extraire la mesure. Ce chapitre s'organise de la façon suivante. La section 4.2 est consacrée à l'étude de la méthode de segmentation en superpixels. La section 4.3 décrit les étapes de la construction de la nouvelle mesure. Nous terminons par une phase d'expérimentation sur des images de synthèse dans la section 4.4 suivie dans la section 4.5 d'une conclusion

4.2. Segmentation en superpixels

Comme indiqué dans le chapitre 1, l'analyse des images à THRS requiert une approche à base d'objets. Néanmoins, cette approche nécessite la définition précise du modèle des objets à étudier comme par exemple le Modèle Numérique de Terrain (MNT) pour l'étude des bâtiments dans les zones urbaines [Crispell et al. 2012]. Cela rend cette méthode supervisée. Dans le cadre de cette thèse qui s'appuie sur les approches non supervisées, nous proposons de contourner cette difficulté par une méthode de segmentation qui est la décomposition des images sous forme de superpixels. Cette approche a déjà été utilisée avec succès pour la détection des changements dans les images à THRS [Wu et al. 2012].

Le principe de la décomposition d'une image sous forme de superpixels consiste à regrouper les pixels en régions atomiques. Cela permet de réduire la redondance de l'information contenue dans l'image et permet le calcul de primitives à échelle locale aisé. La création des superpixels passe par l'exploitation des distances spectrales, des distances de luminance et des affinités texturales entre pixels adjacents afin de créer des clusters de pixels présentant une certaine homogénéité. Dans le cas de l'étude des images à THRS, cette approche est adaptée puisque comme nous l'avons indiqué au chapitre 1, la description d'un objet est influencée par l'ensemble des sous-objets qui le composent. Afin de pallier l'absence de modèle

sémantique pour caractériser un objet, cette décomposition permet la description d'un objet en composantes primaires le constituant.

4.2.1. Décomposition en superpixels

Dans le cas de la construction de notre mesure de similarité, nous allons décomposer chaque composante de la projection de l'image de référence et l'image de changement dans l'espace des descripteurs de texture en régions atomiques sous forme de superpixels. Nous ferons de plus l'hypothèse selon laquelle les deux images ont été mises en correspondance du point de vue radiométrique. Afin d'éviter toute discordance entre les bords des superpixels, une seule carte de superpixels est construite comme dans [Wu et al. 2012]. Pour ce faire, nous allons former un vecteur multicouche à partir des différentes composantes spectrales des images de référence et de l'image de changement. Par la suite une réduction des informations est effectuée à partir de l'analyse en composantes principales. Et les trois premières composantes principales serviront de base pour l'estimation de la segmentation par superpixels. La figure suivante montre un exemple de décomposition en superpixels sur deux images acquises par le satellite QuickBird en Indonésie. L'image de référence est acquise en Avril 2004 tandis que l'image de changement est acquise en Janvier 2005. Les frontières des superpixels sont représentées en rouge. Une analyse visuelle montre qu'une même zone présente dans les deux images est caractérisée par des superpixels avec des contours et des formes identiques.

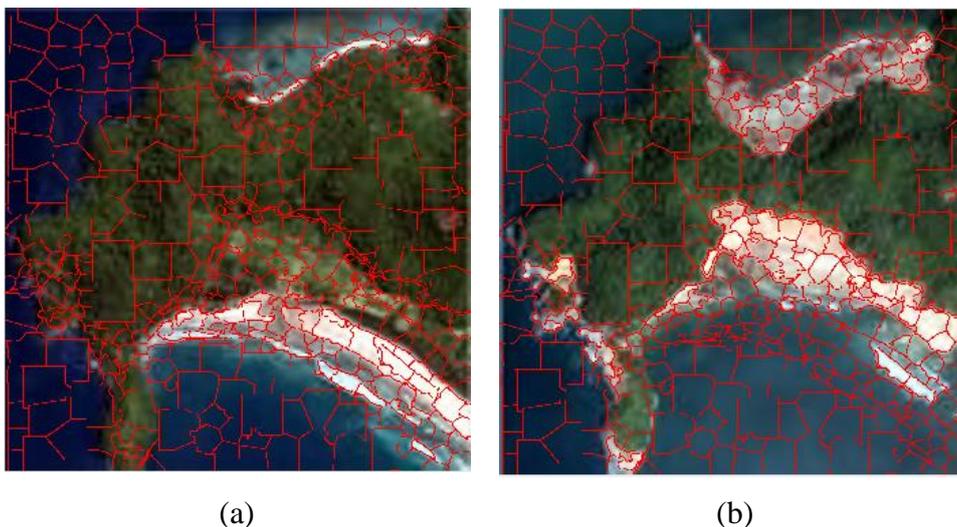


Figure 4. 1 Segmentation en superpixels selon l'algorithme SLIC en 512 superpixels. (a) Décomposition de l'image référence (b) Décomposition de l'image changement

Plusieurs algorithmes de calcul existent dans la littérature [Achanta et al. 2011] pour segmenter une image en superpixels, cependant l'un des plus utilisés à cause de sa simplicité

de programmation et de ses bonnes performances est l'algorithme Simple Linear Interactive Clustering (SLIC) [Achanta et al. 2010] que nous présenterons par la suite.

4.2.2. L'algorithme SLIC

La segmentation en superpixels est fonction de la similarité spectrale et de la corrélation spatiale des pixels. Cela est fait après projection de l'image dans un espace à 5 dimensions appelé espace [labxy] dans lequel l'espace [lab] représente le pixel dans l'espace colorimétrique CIELAB, [xy] représente la position du pixel. Dans cet espace, chaque pixel d'une image situé à la position (x, y) est représenté par le vecteur $[l_i, a_i, b_i, x_i, y_i]^T$, avec l_i, a_i, b_i la représentation de l'intensité du pixel dans l'espace colorimétrique *Lab*, x_i, y_i les coordonnées du pixel et $1 \leq i \leq L \times H$ avec L la largeur de l'image et H la hauteur de l'image. Dans cet espace, une nouvelle distance est définie afin de tenir compte de la similarité spectrale et garantir que les superpixels ont tous une taille relativement égale.

Ainsi si K est le nombre de superpixels désirés et N la taille de l'image, la taille de chaque superpixel est approximativement de N/K et tous les $S = \sqrt{N/K}$ pixels correspondent les centres de chaque superpixel. Soit les K centres de superpixels définis par le vecteur $[l_k, a_k, b_k, x_k, y_k]^T$ pour lesquels $k \in [1, K]$ repartis régulièrement tous les S pixels sur une grille. Considérons alors un voisinage de taille $2S \times 2S$ pixels pris autour de ces centres alors la distance D_S est définie par :

$$D_S = d_{Lab} + \frac{m}{S} d_{xy} \quad (4.1)$$

avec

$$d_{Lab} = \sqrt{(l_k - l_i)^2 + (a_k - a_i)^2 + (b_k - b_i)^2} \quad (4.2)$$

$$d_{xy} = \sqrt{(x_k - x_i)^2 + (y_k - y_i)^2} \quad (4.3)$$

Le coefficient m permet de contrôler la compacité du superpixel. Plus cette valeur est grande plus le superpixel est compact. Les valeurs admises pour ce paramètre sont comprises entre 1 et 20. Dans nos applications, m a été choisi égal à 15 comme indiqué dans [Achanta et al. 2010].

Le principe de l'algorithme est de partir d'un échantillonnage de K centres de clusters de superpixels et de regrouper tous les pixels en région selon le calcul de la distance D_S (cf. Equation 4.1).

Le résultat de la segmentation en superpixels de la figure 4.1 montre le résultat d'une segmentation en 128 superpixels sur deux images d'une même zone côtière acquises à des instants différents. Les images référence (figure 4.1.a) et l'image de changement (figure 4.1.b) sont caractérisées par une homogénéité et une distribution régulière des superpixels. De plus, les bords des superpixels (traits en rouge) coïncident dans les deux images.

L'algorithme SLIC est présenté dans les lignes suivantes.

Algorithme SLIC

Entrée : Image, K =nombre de clusters, m =coefficient de compacité

Sortie : Matrice des superpixels

- 1 Initialisation par échantillonnage des centres des clusters espacés de S par découpage de l'image sur une grille.
 2. Modification des centres des clusters par minimisation du module du gradient sur un voisinage de taille $n \times n$ pris autour du pixel.
 3. Pour chaque centre de cluster C_k , attribution de chaque pixel appartenant à un voisinage de taille $2S \times 2S$, à la classe correspondante par estimation de la distance calculée dans l'équation 4.1.
 4. Mise à jour des centres de clusters (Etape 2) et calcul de l'erreur résiduelle quadratique.
 5. Répéter les étapes (2) à (4) tant que l'erreur quadratique $<$ Seuil.
 6. Affecter les pixels à son cluster.
-

4.3. Estimation de la mesure de similarité

4.3.1. Modélisation statistique des distributions de probabilité marginales

Dans ce paragraphe, nous nous intéresserons à la modélisation statistique des variables aléatoires marginales qui représentent les images fournies par chaque senseur pris individuellement et de la variable aléatoire jointe qui modélise les propriétés statistiques de l'ensemble des images des différents senseurs intervenant dans le processus de détection des changements. En effet, comme mentionné au chapitre 2, la plupart des méthodes de détection

des changements à base de mesure de similarité s'appuient sur une estimation de la fonction de densité de probabilité (f.d.p.) de la variable aléatoire jointe ou des f.d.p. de chacune des variables aléatoires marginales dont le rôle est fondamental dans la construction du masque de changement [Chabert et Tourneret 2011]. De plus, dans cette thèse, nous nous proposons d'utiliser des approches fondées sur la théorie bayésienne. Nous convenons d'adopter un contexte et un formalisme purement statistique dans l'étude de nos images. Une image étant la représentation numérique d'une scène observée, chaque pixel représente par son intensité spectrale une propriété physique d'un objet contenu dans la scène. Et cette intensité est fonction non seulement de l'objet mais aussi de l'interaction des autres objets présents dans la scène. L'estimation de la f.d.p. des variables aléatoires marginales peut se faire de plusieurs façons : par des approches paramétriques aux approches non paramétriques en passant par les approches semi-paramétriques. Cette f.d.p. caractérise la distribution des niveaux de gris des intensités de pixels contenus dans l'image. Dans la suite, nous utiliserons les approches paramétriques qui sont les plus couramment utilisées dans les images de télédétection car l'estimation de la vraisemblance y est optimale à l'aide de modèles adaptés.

4.3.1.1. Images optiques

Les images optiques de télédétection ont été largement étudiées dans la littérature [Liu et al. 2008]. Ces images sont généralement affectées par un bruit additif gaussien. Ainsi si un objet capturé par un satellite optique présente une propriété physique P , alors une bonne modélisation statistique de la f.d.p. caractérisant la propriété physique P de cet objet, capturée est donnée par une loi gaussienne. Ainsi, si x caractérise l'intensité représentant la propriété P d'un objet, nous avons :

$$p(x|P, \theta) = \frac{1}{\sqrt{2\pi\sigma^2}} \exp\left[-\frac{(x - \mu)^2}{2\sigma^2}\right] \quad (4.4)$$

avec $\theta = \{\mu, \sigma^2\}$.

Les paramètres que sont alors la moyenne μ et la variance σ^2 sont alors estimés à l'aide d'algorithmes d'Espérance-Maximisation (EM) ou Stochastique Espérance-Maximisation (SEM) [Celeux 1996]. Plus récemment, Prendes et al. [Prendes et al. 2015] ont proposé une nouvelle interprétation qui stipule que l'intensité spectrale d'un pixel dans une image THRS est la propriété physique de l'objet capturée par le satellite affectée par du bruit. Il en résulte

que la fonction de densité de probabilité traduite par l'équation (4.4) se traduit de la façon suivante. :

$$p(x|P, \theta) \sim N(T_{OPT}, \sigma^2) \quad (4.5)$$

avec T_{OPT} la réponse idéale du satellite et σ^2 la variance du bruit.

4.3.1.2. Les images radar à synthèse d'ouverture (RSO)

Les images acquises par ce type de satellites sont généralement corrompues par un bruit qui est fortement corrélé à l'information capturée. L'amplitude de l'intensité des images radar est donc une exponentielle complexe $Aexp(-i\varphi)$ due à la nature cohérente du signal émis qui se réfléchit sur un objet sondé et qui revient au capteur sous forme de la somme d'une contribution constructive et d'une contribution destructive pour former l'image. Nous allons utiliser une modélisation statistique des amplitudes car comme l'ont indiqué Lee et Jukevich en 1989 [Lee et Jukevich 1989], les amplitudes conduisent à de meilleurs résultats de segmentation. Plusieurs familles de modèles de représentation statistique ont été proposées afin de prendre en compte la présence du bruit multiplicatif présent dans ce type d'images. Ces familles vont des fonctions de densité de probabilité (f.d.p.) théoriques aux fonctions de densité de probabilités (f.d.p.) basées sur des heuristiques [Voisin 2012]. Plus récemment, Li et al. [Li et al. 2011] ont montré l'efficacité des f.d.p. heuristiques notamment de la distribution gamma comme modèle de représentation de la distribution marginale des pixels d'une image radar. Ainsi, si x représente l'intensité d'un pixel d'une image radar représentant la propriété P d'un objet nous avons :

$$p(x|P, \theta) = \frac{\nu}{\sigma \Gamma(k)} \left(\frac{x}{\sigma}\right)^{k\nu-1} \exp\left[-\left(\frac{x}{\sigma}\right)^\nu\right] \quad (4.6)$$

avec $\theta = \{k, \nu, \sigma\}$ la famille des paramètres à estimer de façon paramétrique.

L'intérêt d'une telle loi est qu'elle permet la modélisation d'une large famille de f.d.p. utilisées pour la modélisation statistique des marginales dans les images radar. Elle donne de meilleurs résultats dans la modélisation des histogrammes des images [Li et al. 2011]. Toujours selon la formulation proposée par Prendès et al. en 2015 [Prendès et al. 2015], la f.d.p. de la variable aléatoire marginale précédemment calculée est celle d'une loi gamma

$$p(x|P, \theta) \sim \Gamma\left(L, \frac{T_{RSO}}{L}\right) \quad (4.7)$$

dans laquelle T_{RSO} est la réponse idéale du radar imageur et L le nombre de contributions permettant la construction de l'image.

4.3.2. Distribution jointe

4.3.2.1. Zones homogènes

Supposons que nous disposons de D images I_{S_j} acquises par D différents capteurs satellitaires avec $j = 1, 2, \dots, D$ et intéressons-nous à la variable aléatoire jointe de la propriété physique P caractéristique d'un objet capturé par ces capteurs. C'est le cas d'une zone homogène composée d'un seul objet capturée par plusieurs capteurs différents (Figure 4.2).

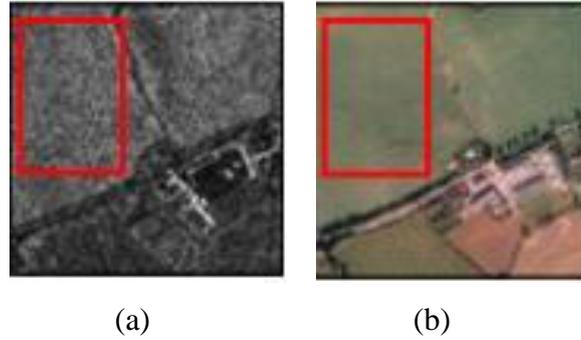


Figure 4. 2 Zone homogène capturée par deux capteurs différents (a) Senseur RSO (b) Senseur optique (Source : Prendes 2015]

Du point de vue statistique, l'intensité $I = (I_{S_1}, I_{S_2}, \dots, I_{S_D})$ est un vecteur aléatoire dont la distribution jointe dépend de l'intensité propre $I_{S_j} | P$ fournie par chaque capteur satellitaire

$$P(I_{S_1}, I_{S_2}, \dots, I_{S_D} | P) = \prod_{j=1}^D P(I_{S_j} | P) \quad (4.8).$$

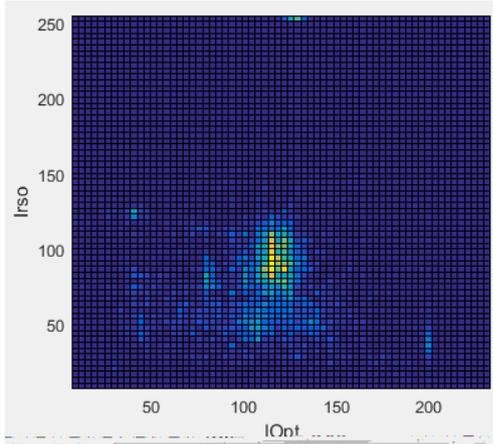
Plus spécifiquement dans les cas couramment rencontrés dans la pratique, pour deux capteurs optiques, nous avons le résultat suivant :

$$P(I_{OPT}, I_{OPT}) = N_P(I_{opt})N_P(I_{OPT}) \quad (4.9)$$

Dans le cas d'un capteur optique et d'un capteur radar, nous avons le résultat :

$$P(I_{OPT}, I_{RSO}) = N_P(I_{opt})\Gamma_P(I_{RSO}) \quad (4.10)$$

De plus le nouveau formalisme introduit par Prendes et al. indique que ces distributions marginales $P(I_{S_j}|P)$ sont entièrement déterminées par la connaissance des réponses idéales T_{S_j} des capteurs à la propriété physique observée. Une conséquence majeure de cette formulation est que l'histogramme joint est entièrement décrit par le graphe des relations entre les différentes réponses idéales. La figure 4.3 montre l'histogramme joint et la distribution des paramètres pour les deux zones encadrées dans la figure 4.2.



(a)

(b)

Figure 4. 3 Histogramme joint et représentation de la courbe d'évolution des paramètres (a) histogramme joint (b) Courbe des paramètres

4.3.2.2. Zone hétérogène

Supposons une zone hétérogène W capturée par D différents capteurs. Chaque capteur fournit une image I_{S_j} de cette zone avec $j = 1, 2, \dots, D$. Nous nous intéressons comme dans le cas du paragraphe précédent à l'estimation de la variable aléatoire jointe $I = (I_{S_1}, I_{S_2}, \dots, I_{S_D})$ en nous plaçant du point de vue statistique. En très haute résolution spatiale, les objets présents sont fortement hétérogènes et l'intensité d'un pixel en un point est généralement le fruit de la combinaison de l'intensité produite par cet objet et des autres objets présents dans les images. Plus généralement si $\mathcal{S} = \{P_k | 1 \leq k \leq K\}$ représente l'ensemble des objets (les superpixels forment des objets atomiques) présents dans la fenêtre W , nous pouvons écrire $W = \bigcup_{k=1}^K P_k$ et par la suite

$$p(P_k|W) = \sum_{k=1}^K \omega_k \delta(P - P_k) \quad (4.11)$$

dans lequel le paramètre ω_k représente la probabilité d'apparition du superpixel P_k dans W . La fonction de densité de probabilité de la variable aléatoire jointe s'écrira alors :

$$p(I|W) = p(I_{S_1}, I_{S_2}, \dots, I_{S_D}|W) = \int_W p(I|P)p(P|W)dS \quad (4.12)$$

$$p(I|W) = \int_W p(I|P_k) \left(\sum_{k=1}^K \omega_k \delta(P - P_k) \right) dS$$

$$p(I|W) = \sum_{k=1}^K \omega_k \int p(I|P_k) \delta(P - P_k) dS$$

$$p(I|W) = \sum_{k=1}^K \omega_k \prod_{j=1}^D P(I_{S_j}|P_k) \quad (4.13)$$

C'est donc un modèle de mélange de densité dont les densités marginales seront soit gaussiennes dans le cas des images optiques, soit des distributions gamma dans le cas des images radars.

4.3.2.3. Nouvelle mesure de similarité

Afin de construire la nouvelle mesure de similarité, nous nous appuyons sur les résultats de la section quatre du chapitre trois et sur les résultats de la section deux du présent chapitre. Nous rappelons les hypothèses de travail. Nous supposons que nous disposons de deux images I_{S_1} et I_{S_2} acquises par deux senseurs. La méthode se voulant générale, la nature du senseur importe peu. Supposons que :

- i) Les images I_{S_1} et I_{S_2} sont segmentées en superpixels conformément au formalisme de la section 4.2
- ii) Pour chacune des images segmentées en superpixels, nous disposons de l'ensemble des matrices des descripteurs de texture $\Omega_{S_i} = \{L_{i,j} | 1 \leq i \leq 2, 1 \leq j \leq 10\}$ conformément au processus décrit à la section quatre du chapitre précédent.

Les images seront analysées par paire de descripteurs pour construire une mesure de similarité par descripteur, avant de construire la mesure de similarité générale.

La mesure de similarité que nous voulons construire s'appuie sur une décomposition des images sous formes de fenêtres notées W . Le choix des fenêtres affectant la qualité de l'algorithme de détection des changements, il convient d'effectuer un choix de fenêtres favorisant un nombre suffisant d'échantillons sans affecter la qualité des estimations. En effet, des fenêtres de grande taille entraînent une surestimation des paramètres tandis que des fenêtres

de petite taille entraînent une forte variabilité de la variance des résultats [Prendes et al. 2015]. Pour ce faire, Prendes et al. proposent l'utilisation de fenêtres de taille $p \times p$ pixels (avec p un nombre entier pair) et se recouvrant les unes des autres à 50%. Chaque fenêtre contient des objets qui ont soit changé d'un senseur à un autre ou qui demeurent inchangés. De plus, la f.d.p de l'intensité jointe d'un pixel contenu dans la fenêtre est définie selon l'équation (4.13) et dépend de l'ensemble d'objets P_1, P_2, \dots, P_K présents dans la fenêtre. Une remarque s'impose. En effet, le nombre K d'objets est à priori inconnu et est déterminé à partir de l'algorithme EM présenté dans la section suivante. Cet algorithme considère le nombre q de différentes classes de superpixels présents dans la fenêtre pour déterminer le nombre K d'objets qui y sont présents.

Ainsi, pour chaque objet P_k présent dans la fenêtre, nous allons définir le vecteur $v(P_k) = [T_{S_1}(P_k), T_{S_2}(P_k)]$ et son estimée $\hat{v}(P_k) = [\hat{T}_{S_1}(P_k), \hat{T}_{S_2}(P_k)]$ à partir de l'équation (4.11). Dans le cas de deux senseurs l'un optique et l'autre radar, l'ensemble des paramètres à estimer pour notre vecteur $v(P_k)$ représentant la propriété P_k est donné par $\hat{\theta} = \{\hat{\mu}, \hat{\sigma}, \hat{k}, \hat{\alpha}\}$ où $\hat{\mu}$ représente la moyenne et σ la variance d'une loi gaussienne pour le senseur optique et \hat{k} et $\hat{\alpha}$ les paramètres de forme et d'échelle pour la loi gamma dans le cas du radar imageur. Il en résulte d'après les équations (4.5) et (4.7) que $\hat{T}_{S_1}(P_k) = \hat{\mu}$ et $\hat{T}_{S_2}(P_k) = \hat{k}\hat{\alpha}$ et donc que $\hat{v}(P_k) = [\hat{\mu}, \hat{k}\hat{\alpha}]$. Un raisonnement analogue montre que dans le cas de deux senseurs optiques $\hat{v}(P_k) = [\mu_1, \mu_2]$ où μ_1 et μ_2 sont les moyennes respectives des lois gaussiennes $N(T_{S_1}, \sigma_1^2)$ et $N(T_{S_2}, \sigma_2^2)$. Un tel vecteur est alors défini pour chaque propriété présente dans la fenêtre et pour l'ensemble des fenêtres rencontrées dans le parcours de l'image. Cela nous permet de construire dans le cas le plus simple une suite de vecteurs v_{W_t} à deux dimensions. Les équations (4.5), (4.7) et (4.13) montrent que le comportement de la distribution jointe est une fonction du vecteur des paramètres $v(P)$.

La mesure de similarité est alors construite par modélisation des dépendances entre les éléments du vecteur $v(P)$. Cette modélisation s'effectuera à l'aide des copules formalisées par Nielsen en 2006 [Nielsen 2006]. L'annexe B décrit le formalisme général des copules bivariées. L'intérêt d'utiliser les copules est de proposer un cadre général de modélisation des dépendances entre les données indépendamment de la connaissance de leurs distributions de probabilité. Cela s'applique bien dans le cas d'approches non supervisées. L'auteur dans [Prendes 2015] définit la mesure de similarité comme l'inverse de la f.d.p. de l'estimée du vecteur de paramètres $\hat{v}(P)$. Afin de tenir compte de la dépendance entre les composantes du

vecteur de paramètres, nous allons construire une nouvelle pseudo-distance de la façon suivante :

$$d_W(\hat{v}_k) = \frac{1}{p(\hat{v}_{k,1})p(\hat{v}_{k,2})[c(\hat{u}_{k,1}, \hat{u}_{k,2}) + c(\hat{u}_{k,2}, \hat{u}_{k,1})]} \quad (4.14)$$

dans laquelle W est la fenêtre d'analyse, sont $\hat{v}_k = [\hat{v}_{k,1}, \hat{v}_{k,2}]$ est l'estimée de la k ième composante du vecteur de paramètres $\hat{v}(P)$, $\hat{u}_{k,1}$ et $\hat{u}_{k,2}$ sont les estimées des fonctions de répartition marginales aux points $\hat{v}_{k,1}$ et $\hat{v}_{k,2}$. $c(\cdot, \cdot)$ est la densité de la copule correspondante.

Comme indiqué dans [Prendes et al. 2014], la pseudo-distance ainsi définie est telle qu'elle prend une faible valeur lorsque la fenêtre correspond à une zone inchangée et une valeur élevée lorsque la zone contenue dans la fenêtre présente des changements. Dans la pratique, les f.d.p. marginales $p(\hat{v}_{\cdot,j})$ avec $j \in \{1, 2\}$ peuvent être estimées par différentes méthodes non paramétriques, notamment par les méthodes à noyau de Parzen et Rosenblatt [Kwak et Choi 2002]. Par la suite, nous posons pour chaque pixel situé à l'intérieur de la fenêtre W la formule suivante :

$$d_{W,t}(I_{S_1}, I_{S_2}) = \sum_{k=1}^K \omega_k d_W(\hat{v}_k) \quad (4.15)$$

dans laquelle ω_k est déterminé en résolvant l'équation (4.13), $d_W(\hat{v}_k)$ représente l'estimée de la pseudo-distance liée à la propriété P_k , calculée selon l'équation (4.14). I_{S_1} et I_{S_2} les intensités des pixels contenus dans la fenêtre, et t le t -ième descripteur dans l'espace des descripteurs de texture.

La nouvelle mesure globale est une contribution de chaque composante de descripteurs. Nous allons la normaliser afin d'avoir des valeurs comprises entre 0 et 1 pour nos applications. Elle est donnée par la formule suivante

$$S(x, y) = \frac{1}{1 + \sum_{i=0}^8 |S_i(x, y) - S_{moy,i}(x, y)|^2} \quad (4.16)$$

avec $S_{moy}(x, y)$ est la moyenne estimée sur les descripteurs $S_i(x, y)$.

4.4. Estimation des paramètres

4.4.1. Sélection de la meilleure copule

La mesure de similarité est une combinaison linéaire de fonction de densité des copules selon l'équation (4.14). La détermination de la meilleure copule est donc primordiale pour la construction de cette mesure. Les auteurs de [Krylov et al. 2011, Voisin et al. 2014] ont montré qu'un dictionnaire composé d'un ensemble de copules à savoir six copules archimédiennes (Clayton, Ali-Mikhail-Haq, Gumbel, Frank, A12, A14), deux copules elliptiques (copule gaussienne, t-Student), une copule quadratique (Farlie-Gumbel-Morgenstern) et une copule non archimédienne (Marchal-Olkin) suffisent à modéliser toutes les relations entre un senseur optique et un senseur radar ou entre deux senseurs radar ou encore entre deux senseurs optiques. Le tableau suivant présente les copules du dictionnaire avec les paramètres nécessaires à leur sélection.

Tableau 4. 1 Dictionnaire des copules et leurs paramètres caractéristiques

Copule	$C_c(u, v \theta)$	$\theta = g(\tau)$	Intervalle de τ
Clayton	$(u^{-\theta} + v^{-\theta} - 1)^{-1/\theta}$	$\theta = \frac{2\tau}{1-\tau}$	$\tau \in (0; 1]$
Ali-Mikhail-Haq	$\frac{uv}{1 - \theta(1-u)(1-v)}$	$\tau = \frac{3\theta-2}{3\theta} - \frac{2}{3}(1 - \frac{1}{\theta})^2 \log(1 - \theta)$	$\tau \in [-0.1817; 0.3333]$
Gumbel	$\exp(-[(-\log(u))^\theta + (-\log(v))^\theta]^{1/\theta})$	$\theta = \frac{1}{1-\tau}$	$\tau \in [0; 1]$
Frank	$-\frac{1}{\theta} \log\left(1 + \frac{(e^{-\theta u} - 1)(e^{-\theta v} - 1)}{e^{-\theta} - 1}\right)$	$\tau = 1 - \frac{4}{\theta^2} \int_0^\theta \frac{t}{e^{-t} - 1} dt$	$\tau \in [-1; 0) \cup (0; 1]$
A 12	$(1 + [(u^{-1} - 1)^\theta + (v^{-1} - 1)^\theta]^{1/\theta})^{-1}$	$\theta = \frac{2}{3 - 3\tau}$	$\tau \in [-0.3334; 1]$
A 14	$(1 + [(u^{-1/\theta} - 1)^\theta + (v^{-1/\theta} - 1)^\theta]^{1/\theta})^{-\theta}$	$\theta = \frac{1 + \tau}{2 - 2\tau}$	$\tau \in [-0.3334; 1]$
FGM	$uv(1 + \theta(1-u)(1-v))$	$\theta = \frac{9}{2}\tau$	$\tau \in [-0.2222; 0.2222]$
Marshall-Olkin	$\min(u^{1-\theta}v, uv^{1-\theta})$	$\theta = \frac{2\tau}{1 + \tau}$	$\tau \in [0; 1]$
Gaussienne	$\int_{-\infty}^{\phi^{-1}(u)} \int_{-\infty}^{\phi^{-1}(v)} \frac{1}{2\pi\sqrt{1-\theta^2}} \exp\left(\frac{2\theta xy - x^2 - y^2}{2(1-\theta^2)}\right) dx dy$	$\theta = \sin\left(\frac{\pi}{2}\tau\right)$	$\tau \in (-1; 1)$
Student	$\int_{-\infty}^{t_v^{-1}(u)} \int_{-\infty}^{t_v^{-1}(v)} \frac{1}{2\pi\sqrt{1-\theta^2}} \left\{1 + \frac{x^2 - 2\theta xy + y^2}{v(1-\theta^2)}\right\}^{-(v+2)/2} dx dy$	$\theta = \sin\left(\frac{\pi}{2}\tau\right)$	$\tau \in (-1; 1)$

Une autre caractéristique des copules du dictionnaire est qu'elles sont toutes entièrement déterminées par la donnée du taux de Kendall. La sélection de la meilleure copule s'effectue alors en deux étapes :

i) Calcul de l'estimateur $\hat{\tau}$ du taux de Kendall τ . Ce calcul se fait à partir de l'analyse de l'échantillon des données de chaque suite de paramètres. Le taux de Kendall se définit de la manière suivante :

$$\tau = \frac{1}{2^{d-1}-1} \left(2^d \int_{[0,1]^d} C(u) dC(u) - 1 \right) \text{ avec } d = 2 \quad (4.17)$$

tandis que sa version estimée est définie par :

$$\hat{\tau} = \frac{4}{N(N-1)} \sum_{i \neq j} 1_{[Y_{1,i} \leq Y_{1,j}]} 1_{[Y_{2,i} \leq Y_{2,j}]} - 1 \quad (4.18)$$

avec N la taille du vecteur aléatoire $Y = (Y_n = (Y_{1,n}, Y_{2,n}) | 1 \leq n \leq N)$.

Dans notre cas le vecteur aléatoire est construit à partir des intensités I_{S_1} et I_{S_2} des pixels contenus dans la fenêtre carrée de taille $N = p \times p$ pixels.

ii) Sélection de la famille $\Pi = \{c^1, c^2, \dots, c^R\}$ de copules éligibles en fonction du taux de Kendall précédemment estimé.

iii) Estimation de la meilleure copule qui se fait à partir du modèle de sélection bayésien proposé par Huard et al. en 2006. Cette approche a été utilisée par Derrode et Pieczynski en 2013 puis en 2016 [Derrode 2013, Derrode 2016] afin de construire un modèle de Chaîne de Markov couple avec copule. L'avantage de cette méthode est qu'elle s'appuie uniquement sur l'estimation du taux de Kendall estimé précédemment et sur une estimation de la densité de la copule.

$$s = \arg \max_{r \in [1;R]} \frac{1}{\tau_M^r - \tau_m^r} \int_{\tau_m^r}^{\tau_M^r} \prod_{n=1}^N c^r(F^1(y_{1,n}), F^2(y_{2,n}), \tau) d\tau \quad (4.19)$$

dans laquelle : τ_M^r et τ_m^r représentent les bornes supérieures et inférieures du taux de Kendall τ^r admissible pour la copule c^r dans la famille des copules éligibles $\Pi = \{c^1, c^2, \dots, c^R\}$ (cf. tableau 4.1).

$F^1(\cdot)$ et $F^2(\cdot)$ sont les fonctions de répartition des variables aléatoires $Y_{1,n}$ et $Y_{2,n}$,

$y = (y_n = (y_{1,n}, y_{2,n}) | 1 \leq n \leq N)$ est un échantillon représentant le vecteur aléatoire

$$Y = (Y_n = (Y_{1,n}, Y_{2,n}) | 1 \leq n \leq N).$$

4.4.2. Estimation des paramètres du mélange des densités

L'estimation de la mesure de similarité passe par l'estimation des vecteurs de paramètres \hat{v} . L'algorithme utilisé est un algorithme EM inspiré de celui de Figueredo [Figueredo et Jain 2002] amélioré par Prendes [Prendes 2015]. Cet algorithme offre l'avantage de permettre une estimation automatique du nombre de composantes du mélange à partir d'un nombre initial de composantes qui décroît selon un critère de minimisation du maximum de vraisemblance. Dans notre cas, ce nombre initial est fourni par le nombre de classes de superpixels présentes dans la fenêtre d'étude W . Si l'algorithme affecte à chaque composante une classe d'objets, une limitation apparaît lorsque deux ou plusieurs objets sont décrits par les mêmes valeurs de paramètres puisque dans ce cas, le pixel ne peut être affecté avec exactitude à la bonne classe. Nous allons présenter en détail l'algorithme EM utilisé puis, nous présenterons le pseudo code de notre algorithme d'estimation des paramètres.

Soient ω_m les poids du mélange de densité, $\theta_m = \{\theta_{m,1}, \theta_{m,2}\}$ un ensemble de paramètre dus à la m -ième composante et $\theta = \{\theta_1, \theta_2, \dots, \theta_m\}$, l'ensemble des paramètres dus à l'ensemble des composantes du mélange. Soit $Y = (Y_n)_{1 \leq n \leq N}$ un vecteur aléatoire continu à valeurs dans \mathbb{R}^2 et dont $y = (Yy_n)_{1 \leq n \leq N}$ est une réalisation.

Une approche classique est de chercher à estimer les paramètres qui minimisent le maximum de vraisemblance. La traduction de ce problème en mathématique consiste à trouver l'ensemble $\hat{\theta} = \{\hat{\theta}_1, \hat{\theta}_2, \dots, \hat{\theta}_m, \hat{\omega}_1, \hat{\omega}_2, \dots, \hat{\omega}_m\}$ tel que :

$$\hat{\theta} = \underset{\theta}{\operatorname{argmax}} \ln(p(Y|\theta)) = \underset{\theta}{\operatorname{argmax}} \sum_{n=1}^N \log\left(\sum_{j=1}^m \omega_j p(y_n|\theta_j)\right) \quad (4.20)$$

avec $p(y_n|\theta_j) = p(y_{n,1}|\theta_{j,1})p(y_{n,2}|\theta_{j,2})$ et le maximum de vraisemblance que nous noterons par la suite $\loglikelihood = \sum_{n=1}^N \log\left(\sum_{j=1}^m \omega_j p(y_n|\theta_j)\right)$

Une estimation directe de l'équation précédente est assez complexe et la façon la plus simple de la résoudre est d'utiliser l'algorithme Espérance-Maximisation (EM) [Dempster et al. 1977] ou sa variante stochastique appelée (SEM) [Celeux 1996]. L'équation précédente est modifiée afin d'introduire les variables latentes $(w_{ij} | 1 \leq i \leq N, 1 \leq j \leq K)$ qui sont les étiquettes

d'appartenance du pixel y_i $1 \leq i \leq N$ à la composante j . Sous les mêmes hypothèses que précédemment, nous estimons donc $\hat{\theta} = \{\hat{\theta}_1, \hat{\theta}_2, \dots, \hat{\theta}_m, \hat{\omega}_1, \hat{\omega}_2, \dots, \hat{\omega}_m\}$ tel que :

$$\begin{aligned} \hat{\theta} &= \operatorname{argmax}_{\theta} \ln(p(Y, \theta)) \\ &= \operatorname{argmax}_{\theta} \sum_{i=1}^N \sum_{j=1}^K w_{ij} \log(\omega_j p(y_i | \theta_j)) - \sum_{i=1}^N \sum_{j=1}^K w_{ij} \log(w_{ij}) \end{aligned} \quad (4.21)$$

avec $w_{ij} = p(j | y_i, \theta)$.

Les étapes de l'algorithme EM qui est un algorithme récursif sont alors les suivantes :

Etape E : A l'étape t pour chaque observation y_i , nous estimons

$$w_{ij}^{(t)} = \frac{\omega_j^{(t)} p(y_i | \theta_j^{(t)})}{\sum_{j=1}^K \omega_j^{(t)} p(y_i | \theta_j^{(t)})} \quad (4.22)$$

Etape M : Estimation des nouveaux paramètres. Dans le cas gaussien, il s'agira des coefficients $\hat{\omega}_j$ de la moyenne $\hat{\mu}_j$ et de la variance $\hat{\sigma}_j$. Ainsi, à chaque itération, nous avons :

$$\hat{\omega}_j^{(t+1)} = \frac{1}{N} \sum_{i=1}^N w_{ij}^{(t)} \quad (4.23)$$

$$\hat{\mu}_j^{(t+1)} = \frac{\sum_{i=1}^N w_{ij}^{(t)} y_i}{\sum_{i=1}^N w_{ij}^{(t)}} \quad (4.24)$$

$$\hat{\sigma}_j^{(t+1)} = \frac{\sum_{i=1}^N w_{ij}^{(t)} (y_i - \hat{\mu}_j^{(t+1)})(y_i - \hat{\mu}_j^{(t+1)})^T}{\sum_{i=1}^N w_{ij}^{(t)}} \quad (4.25)$$

Les paramètres ainsi définis vont nous permettre de construire une loi gaussienne selon l'équation (4.5) ou une loi gamma selon l'équation (4.7).

Nous présentons dans les lignes suivantes, l'algorithme proposé pour notre mesure de similarité.

Algorithme : Paramètres du mélange

Entrée : $I = \{I_1, I_2, \dots, I_N\}$ $K_{max}, K_{min}, n_{iter}, seuil$ **Sortie :** $V = \{v_1, v_2, \dots, v_K\}$, $W = \{\omega_1, \omega_2, \dots, \omega_K\}$

```
1  K = Kmax,
2  bestInflogLikelihood = -Inf
3  Tant que K ≥ Kmin
4    Pour iter allant de 1 à niter faire
5      { V , W } = Algorithme EM
6      kmin = argmink ωk
7      si ωkmin <  $\frac{1}{2N}$  alors
8        K = K - 1
9        Arrêt de la boucle pour
10     Fin si
11     Si |oldV - V| < seuil alors
12       K = K - 1
13       Arrêt de la boucle pour
14     Fin si
15   Fin pour
16    $InfLoglikelihood = Loglikelihood - \frac{1}{2} \sum_{k=1}^K \log(\omega_k) - K \log(N)$ 
17   si InfLoglikelihood > bestInflogLikelihood alors
18     Vbest = V
19     Wbest = W
20     bestInflogLikelihood = InfLoglikelihood
21   Fin si
22 Fin Tant que
23 V = Vbest
24 W = Wbest
```

4.5. Analyse des résultats sur des données de synthèse

Nous allons évaluer les performances de la nouvelle mesure sur des images de synthèse. Les résultats sont évalués et comparés aux mesures de similarités telles que le coefficient de

corrélation (CC) et l'information mutuelle (IM). Les images de synthèse sont extraites de [Prendes 2015] et représentent un ensemble de patchs triangulaires (figure 4.4). Les images sont telles que leur moitié supérieure est changée tandis que la moitié inférieure est inchangée. L'une des images se voit ajouter un bruit gaussien pour simuler un capteur optique (figure 4.4.a) tandis que l'autre se voit ajouter un bruit multiplicatif pour simuler sa version radar (figure 4.4.b). De plus, une hypothèse est faite sur les paramètres. Le vecteur des paramètres $v(P)$ est défini par $v(P) = [T_{OPT}(P), T_{RSO}(P)]$ dont les paramètres sont reliés par la relation quadratique suivante : $T_{RSO}(P) = T_{OPT}(P)[1 - T_{OPT}(P)]$.

La figure suivante illustre les images à comparer ainsi que le modèle vérité terrain qui montre les changements attendus.

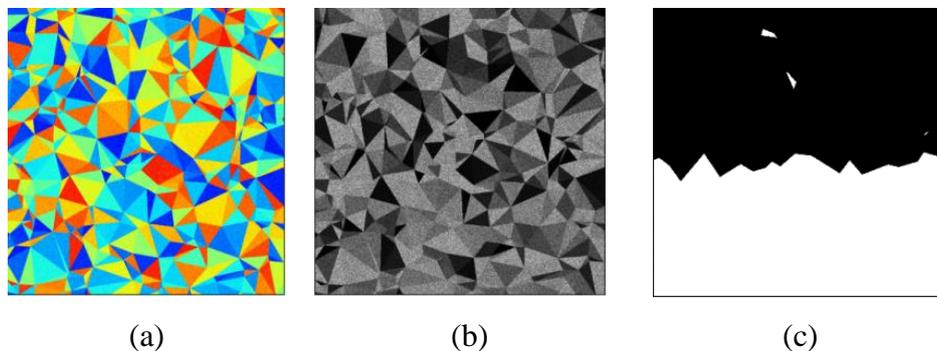


Figure 4. 4 Image de synthèse (a) Capteur optique (b) image radar (c) masque de changement modèle vérité terrain (source : [Prendes 2015])

La figure 4.5 illustre les résultats obtenus par les différents algorithmes testés

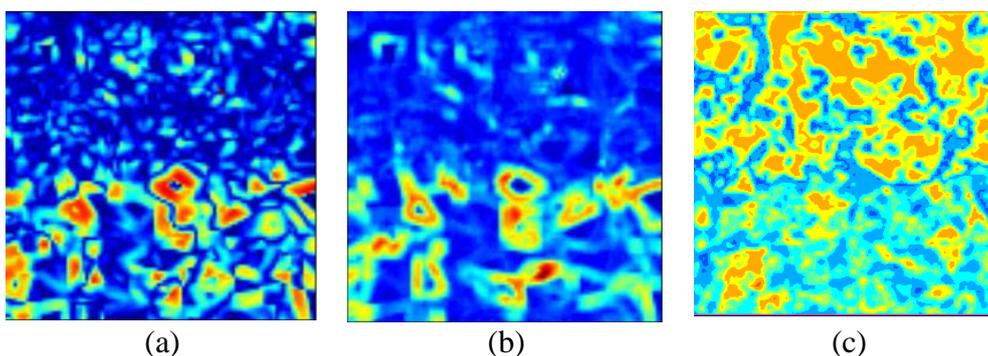


Figure 4. 5 Masque de changement (a) Coefficient de corrélation (b) Information mutuelle (c) Notre approche

Les images de la figure 4.5 ont été obtenues pour des fenêtres d'analyse de 50×50 pixels pour les algorithmes de coefficient de corrélation linéaire et d'information mutuelle et de 20×20 pixels pour notre méthode. Cette différence de taille de fenêtre s'explique par le fait que les deux algorithmes CC et IM ne fournissent des résultats satisfaisant que sur des fenêtres de

grande taille. Quant à notre algorithme, les résultats obtenus sur des fenêtres de taille 50×50 pixels n'augmentent pas sensiblement la qualité des résultats et parfois entraînent une sous-estimation du nombre de composantes ce qui affecte les performances obtenues.

Le résultat attendu des algorithmes testés est de pouvoir discriminer deux zones distinctes dans l'image finale. Une analyse visuelle montre que la nouvelle méthode discrimine mieux les deux zones présentes dans l'image que les algorithmes CC et IM. Une analyse qualitative à base de la courbe de performance du récepteur ou Receiver Operating Characteristic Curve ou courbe ROC du nom de l'acronyme anglais va nous permettre d'évaluer les performances d'un classifieur généralement binaire soumis à différents niveaux de seuils. Le seuil de détection est la probabilité de détection de fausses alarmes (ligne diagonale dans la figure 4.6).

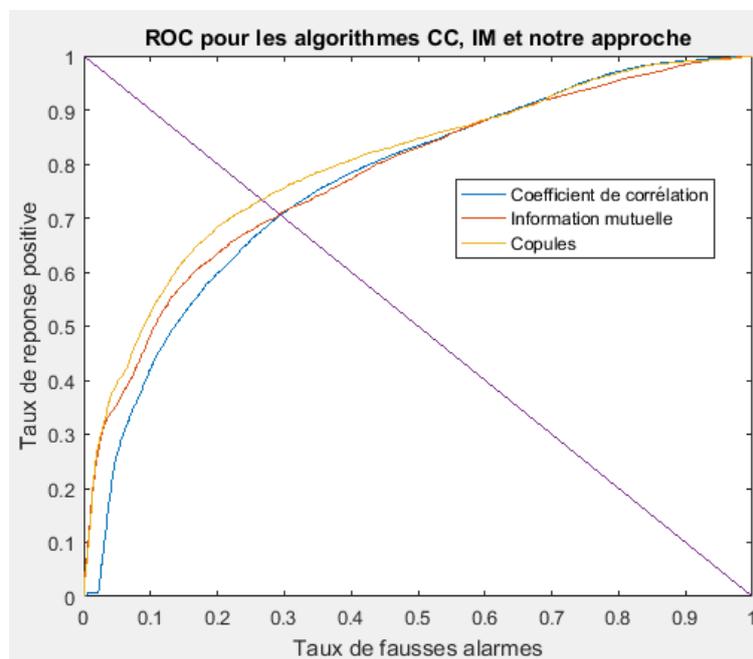


Figure 4.6 Courbe ROC pour les images de synthèse

Le tableau 4.2 illustre les taux de fausses alarmes obtenus pour nos différents algorithmes

Tableau 4. 2 Probabilité de fausses alarmes pour différents algorithmes

Algorithmes	PFA (%)
Coefficient de corrélation linéaire	30.68%
Information mutuelle	28.35%
Notre méthode	26 .05%

Comme attendu, l'algorithme CC présente le plus fort taux de fausses alarmes puisque le modèle utilisé pour la construction des images présente une relation de dépendance quadratique alors que le CC ne détecte que les dépendances linéaires. L'information mutuelle souffre quant à lui de l'estimation de la f.d.p. de la distribution jointe puisqu'il y ait fait l'hypothèse d'une indépendance des distributions de probabilité. Ce qui n'est pas le cas dans notre hypothèse. Quant à notre modèle, il fournit les meilleurs résultats cependant, les mauvaises détections sont liées aux limitations de l'algorithme EM, notamment à sa capacité à discerner sans ambiguïté deux classes de paramètres relativement proches.

4.6. Conclusion

Dans ce chapitre, nous avons proposé une nouvelle mesure permettant de construire le masque de changement. Cette mesure se construit autour de deux étapes principales (figure 4.7). La première étape est un processus de segmentation en régions atomiques appelé décomposition en superpixels. La seconde étape consiste en la construction de la nouvelle mesure à partir de la modélisation des dépendances à l'aide des copules entre les composantes d'un vecteur de paramètres qui caractérise le comportement de la distribution jointe. La mesure est construite pour chaque composante des images des senseurs dans l'espace des descripteurs de texture. Puis, une mesure globale est calculée pour l'ensemble des descripteurs. Il faut remarquer que la décomposition en superpixels est un processus de sur-segmentation de l'image et l'algorithme EM utilisé nous permet d'obtenir pour chaque fenêtre d'analyse, le nombre de composantes ou d'objets présents. Les premiers tests effectués par notre approche face aux mesures de similarité statistiques couramment rencontrées dans la littérature donnent de meilleures performances dans la détection des zones changées. Cependant, notre mesure souffre de deux limitations. Tout d'abord, l'algorithme EM peut être affecté de mauvaise classification surtout lorsque les paramètres représentant deux objets distincts sont relativement proches, et d'autre part la mesure de similarité ne prend pas en compte le contexte spatial des différentes images puisqu'elle est fondée sur la modélisation des dépendances entre les différents senseurs et non à l'intérieur des senseurs eux-mêmes. Le chapitre suivant bâti autour des chaînes de Markov se propose de résoudre cette seconde limitation.

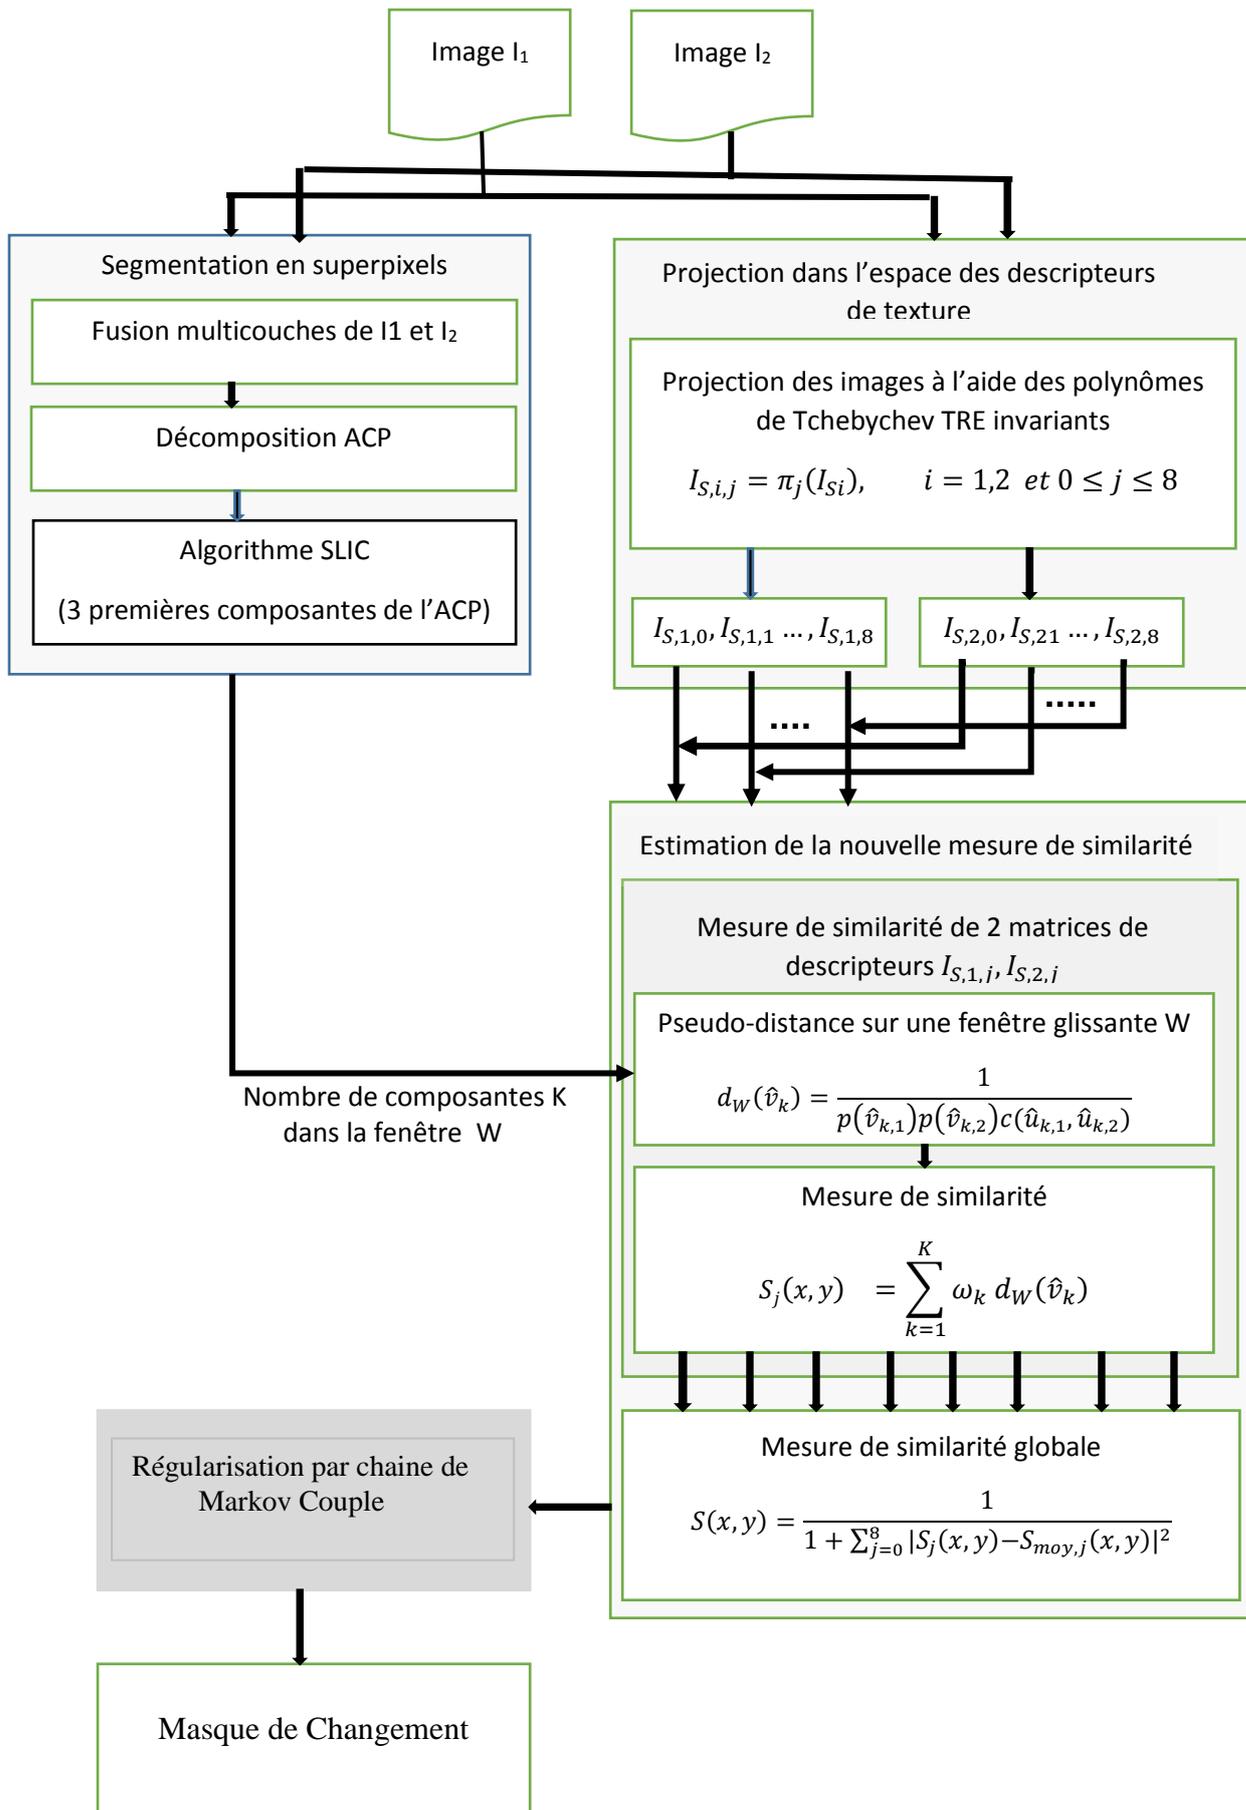


Figure 4.7 Nouvel algorithme de détection de changements

Chapitre 5

Estimation non paramétrique des chaînes de Markov couple

Sommaire

5.1. Introduction	93
5.2. Rappel sur les chaînes de Markov couple avec copules	94
5.2.1. Rappels préliminaires sur les chaînes de Markov couple.....	94
5.2.2. Définition des chaînes de Markov couple avec copule	97
5.3. Estimation de la densité de la copule à l'aide des polynômes orthogonaux.....	100
5.3.1. Rappel sur les copules	100
5.3.2. Estimation de la densité de la copule à l'aide des polynômes orthogonaux.....	103
5.4. Restauration MPM des chaînes de Markov couple.....	106
5.5. Estimation des paramètres des chaînes de Markov couple	107
5.6. Analyse et évaluation des résultats sur des images de synthèse	109
5.7. Analyse et évaluation des résultats sur des images réelles.....	114
5.7.1. Cas de deux images acquises par le même capteur.....	115
5.7.2. Cas de deux images acquises par des capteurs optiques différents	119
5.7.3. Cas de deux capteurs hétérogènes.....	121
5.8. Conclusion	125

5.1. Introduction

Dans le chapitre quatre, nous avons proposé un modèle de construction de masque de changements à partir d'une nouvelle mesure de similarité. Cette mesure de similarité s'est appuyée sur les propriétés statistiques de la distribution des paramètres des différents pixels. L'estimation de ces paramètres a été effectuée à l'aide de l'algorithme EM adapté à un modèle de distribution à base de mélange de densité. Malheureusement, cette nouvelle mesure de similarité souffre de deux défauts. Tout d'abord, le nombre de composantes du mélange de densité est fixé a priori et influence le choix de la taille des fenêtres d'analyse qui doit être relativement importante [Prendes et al. 2014]. Les auteurs de [Figueredo et Jain 2002] puis de [Prendes et al. 2014] ont proposé des algorithmes qui permettent de déterminer le nombre optimal de composantes. D'autre part, la corrélation spatiale entre les pixels n'est pas prise en compte dans l'estimation des paramètres du modèle EM. Pour pallier cette limitation nous allons régulariser la matrice de similarité à l'aide d'un modèle markovien, notamment d'une chaîne de Markov couple qui dans sa formulation tient compte de la corrélation spatiale des observations. Afin de modéliser cette dépendance entre les observations, Brunel et Pieczynski [Brunel et Pieczynski 2005] ont introduit dans les chaînes de Markov, la notion de copule [Sklar 1959] couramment utilisée en théorie des probabilités et des statistiques. En 2013, Derrode et Pieczynski dans [Derrode et Pieczynski 2013] ont proposé un modèle de sélection automatique de la copule dans le cas des chaînes des Markov couple. Cependant, la grande difficulté de manipulation des copules demeure leur estimation puisque dans la pratique, elles sont généralement inconnues.

Trois approches sont généralement courantes en statistique pour l'estimation des copules: les approches paramétriques, les approches semi-paramétriques et les approches non paramétriques. L'approche paramétrique impose un modèle spécifique pour les marginales et pour la copule, quant à l'approche semi-paramétrique, elle détermine les fonctions de densité des probabilités (f.d.p) des distributions marginales de façon non paramétrique et estime la densité de la copule de façon paramétrique. L'approche non paramétrique quant à elle estime de façon non paramétrique les f.d.p des distributions marginales et la densité de la copule.

Dans les sections suivantes, nous allons tout d'abord rappeler le formalisme général des chaînes de Markov couple (cf. section 5.2), puis nous introduirons la notion de copule dans les chaînes de Markov couple (cf. section 5.3) et l'estimation des paramètres de ce nouveau modèle (cf. section 5.4). La validité des résultats obtenus sera établie par des expériences sur des images

de synthèse (cf. section 5.5) et des images réelles (cf. section 5.6). Nous allons terminer ce chapitre par une conclusion (cf. section 5.7).

5.2. Rappel sur les chaines de Markov couple avec copules

5.2.1. Rappels préliminaires sur les chaines de Markov couple

Nous allons définir dans ce paragraphe, les notations nécessaires utiles pour l'étude des chaines de Markov couple avec copule. Il est à noter que les chaines de Markov couple sont des modèles graphiques comportant des données observées et des données latentes. On note $y_{1:N} = (y_1, y_2, \dots, y_n)$ les données observées, qui sont issues de la réalisation d'un processus aléatoire $Y_{1:N} = (Y_1, Y_2, \dots, Y_n)$ défini sur un réseau monodimensionnel et les données latentes $x_{1:N} = (x_1, x_2, \dots, x_n)$ qui sont issues de la réalisation d'un processus aléatoire $X_{1:N} = (X_1, X_2, \dots, X_n)$. Nous ferons par la suite les hypothèses que les X_n sont à valeurs discrète et que les Y_n sont à valeur réelles et continues.

Tout d'abord, nous allons définir la notion de processus markovien [Ben Mabrouk 2012].

Définition 5.2.1 (Chaîne de Markov)

Soit $X_{1:N}$ un processus aléatoire avec les X_n à valeurs dans un espace discret $\Omega = \{\omega_1, \omega_2, \dots, \omega_K\}$. Soit p une probabilité définie sur Ω . On dit que X est une chaîne de Markov si et seulement s'il admet comme graphe d'indépendance conditionnelle non-orienté le graphe où chaque site n admet son prédécesseur $n - 1$ si $n > 0$ et son successeur $n + 1$ si $n < N$ comme voisins (figure 5.1)

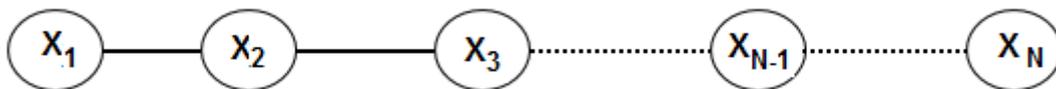


Figure 5. 1 Graphe d'indépendance conditionnelle non-orienté d'une chaîne de Markov

Autrement dit, le processus aléatoire $X_{1:N}$ vérifie la propriété suivante :

$\forall n \geq 0, \forall \omega_1, \omega_2, \dots, \omega_n \in \Omega$, nous avons

$$p(X_n = \omega_n | X_1 = \omega_1, X_2 = \omega_2, \dots, X_{n-1} = \omega_{n-1}) = p(X_n = \omega_n | X_{n-1} = \omega_{n-1}) \quad (5.1)$$

Remarque 5.2.1

- Une chaîne de Markov est dite homogène si les transitions $p(x_{n+1}|x_n)$ ne dépendent pas de n . La loi d'une chaîne de Markov homogène est alors entièrement déterminée par sa loi initiale $p(x_1)$ et les transitions $p(x_{n+1}|x_n)$.
- Une chaîne de Markov est stationnaire si elle est homogène et si la loi marginale $p(x_n)$ ne dépend pas de n . La loi initiale est alors appelée loi invariante ou stationnaire.
- En utilisant les propriétés de la markoviannité globale [Ben Mabrouk 2012], nous avons alors que $X_{1:n-1}$ et $X_{n+1:N}$ sont indépendantes conditionnellement à X_n :

$$p(x_{1:N}) = p(x_{1:n-1}|x_n)p(x_{n+1:N}|x_n) \quad (5.2)$$

En effectuant une récurrence sur la sous-chaîne $X_{1:n-1}$, nous avons le résultat suivant :

$$p(x_{1:N}) = p(x_1) \prod_{k=2}^N p(x_k|x_{k-1}) \quad (5.3)$$

Dans toute la suite, nous allons désigner par $\pi_i = p(x_1 = \omega_i)$ la loi de la probabilité initiale au point, et $A = (a_{ij})_{1 \leq i, j \leq K}$ la matrice des transitions $a_{ij} = p(x_{n+1} = \omega_j | x_n = \omega_i)$

En traitement d'images, l'image 2-D est représentée sous la forme d'un vecteur 1-D à l'aide de la transformation de Hilbert-Peano. Le parcours d'Hilbert-Peano [Benmiloud et Pieczynski 1995]. Le parcours est représenté par la figure 5.1

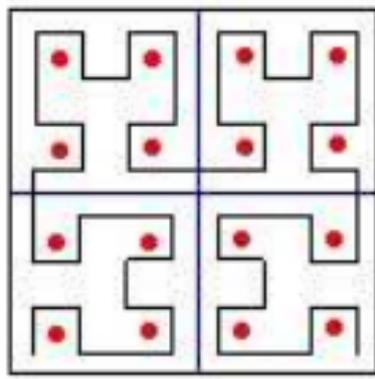


Figure 5. 2 Parcours de Hilbert-Peano pour une image de taille 4x4 pixels

L'avantage de cette transformation est qu'elle permet de garder deux points voisins dans la chaîne des voisins 1-D de l'image. Cependant, deux points voisins dans l'image peuvent ne pas l'être dans la chaîne [Benmiloud et Pieczynski 1995].

Dans toute la suite, nous allons considérer le processus aléatoire $Z_{1:N} = (X_{1:N}, Y_{1:N})$ couple à temps discret, défini de la façon suivante : $\forall n \in \mathbb{N}$ tel que $1 \leq n \leq N$, $Z_n = (X_n, Y_n)$ avec X_n et Y_n à valeurs respectivement dans un espace discret $\Omega = \{\omega_1, \omega_2, \dots, \omega_K\}$ pour la variable aléatoire X_n et dans \mathbb{R} pour la variable aléatoire Y_n . La variable aléatoire Y_n est une variable aléatoire continue.

Définition 5.2.2 (Chaîne de Markov couple)

Un processus aléatoire couple $Z_{1:N}$ est une chaîne de Markov couple si et seulement si, il admet pour graphe d'indépendance conditionnelle le graphe présenté à la figure 5.1.

Le processus couple $Z_{1:N}$ est markovien sans que les processus $X_{1:N}$ ni $Y_{1:N}$ ne soient markoviens.

Le graphe d'indépendance conditionnelle non-orienté d'un tel modèle est donné par :

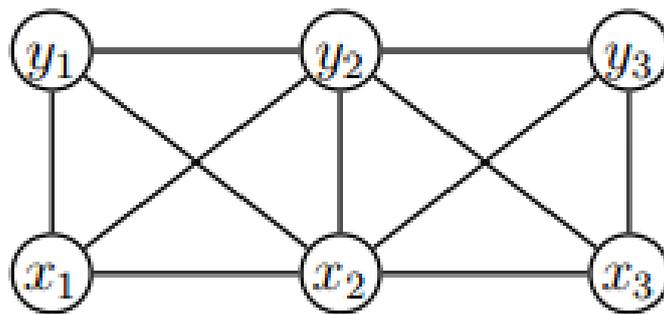


Figure 5. 3 Graphe de dépendance conditionnelle non orienté d'une chaîne de Markov couple

Bien entendu, une CM couple (CMCo) vérifie alors les propriétés classiques des chaînes de Markov. En particulier, nous pouvons écrire que la loi de $Z_{1:N}$ est si nous considérons une réalisation $z_{1:N} = (z_1, z_2, \dots, z_n)$ de $Z_{1:N}$:

$$p(z_{1:N}) = p(z_1) \prod_{k=2}^N p(z_k | z_{k-1}) \tag{5.4}$$

Les probabilités de transition sont alors [Derrode et Pieczynski 2004] :

$$p(z_k | z_{k-1}) = p(x_k, y_k | x_{k-1}, y_{k-1}) \tag{5.5}$$

$$= p(x_k | x_{k-1}, y_{k-1}) p(y_k | x_k, x_{k-1}, y_{k-1}) \tag{5.6}$$

La détermination des probabilités $p(x_k|x_{k-1}, y_{k-1})$ et $p(y_k|x_k, x_{k-1}, y_{k-1})$ déterminent entièrement le comportement du processus aléatoire Z_{1N} .

5.2.2. Définition des chaînes de Markov couple avec copule

Depuis les premières applications pratiques par Rabiner en 1989 [Rabiner 1989], les modèles de Markov cachés sont devenus un outil essentiel en segmentation d'images et ont été appliqués dans divers domaines [Siachalou et al. 2015, Szyrani et al. 2014, Baumgartner et al. 2014, Mari et al. 2013]. Les premiers modèles, relativement simples, [Geman et Geman 1984, Baum et al. 1970] qui supposent l'indépendance des observations conditionnellement aux classes d'appartenance, ont connu plusieurs extensions. Dans ces modèles, la vraisemblance des données modélisée à l'aide d'une loi jointe, suppose l'introduction d'une hypothèse d'indépendance des observations. Ainsi, les modèles de Markov couple [Pieczynski 2003] et les modèles de Markov triplet [Pieczynski 2002] ont été proposés afin de mieux prendre en compte les relations de dépendance entre les différents pixels de l'image. Les modèles couple dont fait partie les chaînes de Markov couple sont aujourd'hui le modèle de base des méthodes markoviennes. Ces modèles offrent une complexité calculatoire identique aux chaînes de Markov avec bruit indépendant (CMC-BI). Ils autorisent la prise en compte des interactions entre les observations, contrairement au modèle CMC-BI qui implique des hypothèses simplificatrices non adaptées aux cas des images présentant des scènes réelles. Nous allons dans cette section étudier le formalisme de ce modèle.

En segmentation des images par chaîne de Markov couple, nous faisons l'hypothèse que l'image segmentée est représentée du point de vue statistique par un processus aléatoire $X_{1:N} = (X_1, X_2, \dots, X_N)$ à valeurs discrètes dans un espace fini Ω à K éléments ou classes. L'image observée est représentée du point de vue statistique par un processus aléatoire $Y_{1:N} = (Y_1, Y_2, \dots, Y_N)$ est continu et à valeurs réelles. $Y_{1:N}$ représente la version bruitée de l'image segmentée.

Les variables aléatoires X_n sont discrètes et prennent leur valeur dans l'ensemble fini $\Omega = \{1, 2, \dots, K\}$ représentent les données latentes. Les variables aléatoires réelles Y_n représentent les données observées. Nous noterons dans la suite $x_{1:N} = (x_1, x_2, \dots, x_N)$ une réalisation du processus aléatoire $X_{1:N} = (X_1, X_2, \dots, X_N)$ et $y_{1:N} = (y_1, y_2, \dots, y_N)$ une réalisation du processus aléatoire $Y_{1:N} = (Y_1, Y_2, \dots, Y_N)$. Le principe étant d'estimer $X_{1:N}$ en fonction de $Y_{1:N}$. Le modèle des chaînes de Markov cachés qui propose une méthode optimale pour la

résolution de ce problème est caractérisée par la loi de probabilité du processus aléatoire $Z_{1:N}$, suivante [Benmiloud et Pieczynski 1995] :

$$p(x_{1:N}, y_{1:N}) = p(x_1) \prod_{k=2}^N p(x_k | x_{k-1}) p(y_k | x_k) \quad (5.7)$$

dans laquelle $x_{1:N} = (x_1, x_2, \dots, x_N)$ et $y_{1:N} = (y_1, y_2, \dots, y_N)$ sont une réalisation des processus $X_{1:N}$ et $Y_{1:N}$ respectivement ;

$p(x_1)$ est la loi de probabilité de la variable aléatoire initiale X_1 en x_1 ;

$p(y_k | x_k) = f_{x_k}(y_k)$ est la fonction de densité de probabilité de la variable aléatoire Y_k conditionnellement à X_k en y_k .

Deux hypothèses supplémentaires sont ajoutées [Benmiloud et Pieczynski 1995] :

- (i) $X_{1:N}$ est un processus markovien
- (ii) Les variables aléatoires Y_n conditionnellement à X_n sont supposés indépendants c'est-à-dire que $p(y_{1:N} | x_{1:N}) = \prod_{k=1}^N p(y_k | x_k)$ pour toute réalisation $x_{1:N} = (x_1, x_2, \dots, x_N)$ et $y_{1:N} = (y_1, y_2, \dots, y_N)$ des processus $X_{1:N}$ et $Y_{1:N}$ respectivement

Cela constitue une limitation notamment lors de l'analyse des images complexes. Ces limitations apparaissent surtout dans le cas de la segmentation des images de télédétection qu'elles soient de type optique ou radar dans lesquelles les intensités des pixels sont modélisées par des distributions statistiquement dépendantes. De plus, le processus caché recherché n'est pas nécessairement markovien et cette hypothèse n'est pas nécessaire dans l'estimation du processus caché [Derrode et Pieczynski 2004]. Pour résoudre ces limitations des modèles plus évolués que sont les chaînes de Markov couple ont été introduits.

Dans ce paragraphe, nous rappelons les principes de bases des chaînes de Markov couple avec copule. Ce modèle a été introduit afin de pallier les insuffisances dues aux hypothèses simplificatrices qui constituent le cœur des modèles de Markov cachées tout en conservant une complexité algorithmique et calculatoire similaire. Ce modèle dont les principes élémentaires ont été définis précédemment (cf. définition 5.2.2) s'appuie sur le résultat fondamental suivant [Derrode et Pieczynski 2004, Derrode et Pieczynski 2013] :

$$p(x_{1:N}, y_{1:N}) = p(x_1, y_1) \prod_{k=2}^N p(x_k, y_k | x_{k-1}, y_{k-1}) \quad (5.8)$$

avec $z_{1:N} = (z_1, z_2, \dots, z_N)$ une réalisation du processus aléatoire couple $Z_{1:N} = (Z_1, Z_2, \dots, Z_N)$ dans lequel $Z_n = (X_n, Y_n)_{1 \leq n \leq N}$.

Nous supposons le processus $Z_{1:N}$ stationnaire et réversible, ce qui suppose que le processus $Z_{1:N}$ vérifie les deux conditions suivantes [Derrode et Pieczynski 2013] :

- (i) les probabilités $p(z_{n-1}, z_n)$ sont indépendantes de l'entier n
- (ii) $p(z_n|z_{n-1}) = p(z_{n-1}|z_n)$ (5.9)

Une telle chaîne de Markov couple est appelée chaîne de Markov couple stationnaire et réversible.

Les probabilités de transition sont alors [Derrode et Pieczynski 2004] :

$$p(z_k|z_{k-1}) = p(x_k|x_{k-1}, y_{k-1})p(y_k|x_k, x_{k-1}, y_{k-1})$$

Nous avons par la suite

$$p(x_k|x_{k-1}, y_{k-1}) = \frac{p(x_k, x_{k-1}, y_{k-1})}{p(x_{k-1}, y_{k-1})} \quad (5.10)$$

$$= \frac{p(y_{k-1}|x_k, x_{k-1}) \times p(x_k, x_{k-1})}{\sum_{j=1}^K p(x_k = j, x_{k-1}, y_{k-1})} \quad (5.11)$$

$$= \frac{f_{x_k x_{k-1}}(y_{k-1})p(x_k, x_{k-1})}{\sum_{j=1}^K f_{x_k=j, x_{k-1}}(y_{k-1})p(x_k=j, x_{k-1})} \quad (5.12)$$

avec $f_{x_k x_{k-1}}(y_{k-1}) = \int f_{x_k, x_{k-1}}(y_k, y_{k-1}) dy_k$

et

$$p(y_k|x_k, x_{k-1}, y_{k-1}) = \frac{p(y_k, y_{k-1}|x_k, x_{k-1})}{p(y_{k-1}|x_{k-1}, x_k)} = \frac{f_{x_k x_{k-1}}(y_k, y_{k-1})}{f_{x_{k-1} x_k}(y_{k-1})} \quad (5.13)$$

En utilisant l'équation (B.6) de l'annexe B, et le fait que la chaîne de Markov $Z_{1:N}$ est réversible nous avons que :

$$f_{x_k x_{k-1}}(y_k, y_{k-1}) = f_{x_k x_{k-1}}(y_k) f_{x_{k-1} x_k}(y_{k-1}) c \left(F_{x_k x_{k-1}}^{(1)}(y_k), F_{x_{k-1} x_k}^{(2)}(y_{k-1}) \right) \quad (5.14)$$

Comme le processus $Z_{1:N}$ est supposé homogène et réversible, alors les équations sont indépendantes de n . Par la suite, le processus $Z_{1:N}$ est entièrement déterminé par la connaissance des probabilités $p(x_1, x_2)$ et des fonctions de densité de probabilité $f_{x_1, x_2}(y_1, y_2) = p(y_1, y_2|x_1, x_2)$ définies sur \mathbb{R}^2 . Plus précisément, il faudra alors déterminer selon [Derrode et Pieczynski 2013, Derrode et Pieczynski 2016] :

- K probabilités initiales définies par le vecteur $\pi = (\pi_i)_{1 \leq i \leq K} = p(X_1 = i)_{1 \leq i \leq K}$

- $(K(K+1)/2) - 1$ probabilités conjointes à priori $p(x_1, x_2)$ caractérisées par la matrice des probabilités conjointes $P = (p_{ij})_{1 \leq i \leq K, 1 \leq j \leq K}$ et la matrice des transitions
- $A = (a_{ij})_{1 \leq i, j \leq K} = p(x_{n+1} = j | x_n = i)$.
- K^2 fonctions de densité de probabilité bidimensionnelles $f_{x_1 x_2}(y_1, y_2)$ qui mesurent la variabilité des observations reliées aux K^2 densités marginales. Dans le cas gaussien cela passe par la donnée de la moyenne μ de la variance σ et de la corrélation ρ des densités marginales.
- La copule C dont la fonction de densité $c(F_{x_1 x_2}^{(1)}(y_1), F_{x_1 x_2}^{(2)}(y_2) | x_1, x_2) = c_{x_1 x_2}(F_{x_1 x_2}^{(1)}(y_1), F_{x_1 x_2}^{(2)}(y_2))$ dans laquelle les $F_{x_1 x_2}^{(i)}$ représentent les fonctions de répartition associées aux fonctions de densités de probabilités $f_{x_1 x_2}^{(i)}(\cdot) = p(\cdot | x_1, x_2)$.

Le problème principal est l'estimation de la fonction de densité de la copule associée aux variables d'observation. Nous allons étudier dans les paragraphes suivants une méthode d'estimation de la densité de la copule basée sur les polynômes de Legendre.

5.3. Estimation de la densité de la copule à l'aide des polynômes orthogonaux

5.3.1. Rappel sur les copules

Dans la suite, nous allons présenter un modèle couramment utilisé en télédétection pour modéliser les dépendances spatiales. Ce sont les copules bidimensionnelles. Leur intérêt est qu'elles permettent d'estimer la fonction de densité de probabilité de la variable aléatoire jointe en tenant compte de l'information contenue dans chacune des lois des variables aléatoires marginales. Nous allons appliquer la définition B.1.1 (cf. Annexe B) et le théorème de Sklar (cf. Annexe B) à notre étude. Soient Y_1, Y_2 deux variables aléatoires continues dont une réalisation est représentée par y_1, y_2 . Soit la fonction de répartition conjointe H et F_1, F_2 les fonctions de répartition marginales des variables aléatoires marginales Y_1, Y_2 alors, il existe une copule C (cf. Annexe B) telle que :

$$H(y_1, y_2) = C(F_1(y_1), F_2(y_2)) \quad (5.15)$$

Etant donné que les fonctions de répartition F_1, F_2 sont continues, la copule est continue et unique. La fonction de densité de probabilité jointe est donnée par :

$$f(y_1, y_2) = c(F_1(y_1), F_2(y_2)) \prod_{i=1}^{d=2} f_i(y_i) \quad (5.16)$$

dans laquelle c représente la fonction de densité de la copule et les $f_i(.)$ les fonctions de densités de probabilité des variables aléatoires marginales. La définition d'une copule ne spécifie pas la loi associée à la fonction de répartition, ni celle associée aux variables aléatoires marginales. Plusieurs configurations de copules sont donc possibles. Ainsi, dans le cas des images radar, les auteurs de [Voisin et al. 2013] ont montré que les copules de Clayton et de Gumbel sont les plus performantes dans le sens où elles sont un bon compromis entre complexité calculatoire et précision des résultats. De même, pour les images optiques les auteurs de [Stitou et al. 2009] définissent deux types de copules gaussiennes dont les marginales sont décrites soit par une loi Gamma (Gamma multivariée sur copule gaussienne), soit par une gaussienne généralisée GGD (GGD multivariée sur copule gaussienne). Les auteurs de [Lasmar et Berthoumieu, 2014] proposent quant à eux une distribution Weibull multivariée sur copule Gaussienne et dérivent de cette proposition une forme analytique de la divergence de Kullback-Liebler (Kullback-Liebler Divergence). Dans [Kwitt et Uhl, 2009], les auteurs présentent une distribution Weibull multivariée sur une copule de Student-t et suggèrent une stratégie d'estimation de la KLD pour cette distribution par une approche Monte-Carlo.

Malheureusement, s'il existe une littérature abondante pour le cas de variables aléatoires marginales appartenant à une même famille de capteurs, le cas de variables aléatoires marginales modélisant les statistiques de capteurs hétérogènes demeure très peu étudié à notre connaissance. Dans le cas de cette thèse, nous avons choisi une estimation non paramétrique de la densité des copules.

L'approche classique pour résoudre ce problème consiste à utiliser une méthode d'estimation paramétrique [Derrode et Pieczynski 2013]. Dans ce cas, les f.d.p. des variables aléatoires marginales et la copule sont supposées appartenir à des familles de lois spécifiques. L'on cherche alors à estimer la meilleure loi qui correspond aux f.d.p. des variables aléatoires marginales ou à la copule dans cette famille. La principale limitation des méthodes paramétriques réside dans le fait qu'elles sont fortement dépendantes de la famille de copule choisie et toute mauvaise modélisation de la copule entraîne une dégradation du résultat surtout dans les queues de distribution. Des alternatives ont été proposées notamment l'approche semi paramétrique.

Dans cette approche, un modèle spécifique est imposé à l'estimation de la copule, tandis que les f.d.p. des variables aléatoires marginales sont estimées par une approche non paramétrique [Kim et al. 2007].

Dans le cas de l'approche non paramétrique, il est suggéré l'utilisation de modèles non paramétriques pour l'estimation de la copule et des lois marginales. Il convient d'estimer la forme de la distribution de la copule à partir des seules données disponibles. Les auteurs de [Kauermann et al. 2013] proposent une revue exhaustive des méthodes d'estimations non paramétrique de la densité de la copule. La méthode la plus courante est d'estimer la densité de la copule à partir d'estimateur à l'aide des noyaux de Parzen et Rozenblatt. Cependant, ces estimateurs souffrent de deux défauts majeurs que sont l'apparition d'un effet de bord au voisinage des bornes de l'intervalle $[0, 1]$ [Buch-Larsen 2005] et la difficulté de détermination du paramètre de lissage optimal [Heidenreich 2013]. De plus, les temps de calcul sont relativement importants dans le cas de l'estimation d'échantillons de grande taille.

Des méthodes de réflexions et des méthodes adaptatives ont été proposées pour résoudre ces problèmes de paramètres de lissage [Vikram et al. 2014] et de biais aux bornes [Malec et Schienle 2014]. D'autres méthodes alternatives ont été proposées tel que la transformation des données [Chen et Huang 2007], l'utilisation des noyaux à support compact dont font partie les noyaux beta [Chen 2000] et les polynômes de Bernstein [Bouezrmani 2013]. Une autre approche intéressante est l'estimation de la copule par les séries orthogonales introduites par Effromovitch [Effromovitch 2010] afin de réduire les temps de calcul et la complexité calculatoire du paramètre de lissage. Cette méthode a été prolongée par Amali Dassanayake et al. [Dassanayake et al. 2015] et est facilement extensible à l'estimation des densités de distributions multivariées. Tout récemment, Yang et al. dans [Yang et al. 2014] ont proposé un nouvel algorithme de segmentation à base de champ de Markov caché. Ces champs sont estimés à partir de l'analyse des lignes de niveau du spectre d'énergie. C'est une approche contour qui s'appuie sur l'analyse de la détection des contours par ligne de niveaux [Wang et al. 2013, Wang et al. 2014]. Cette approche combine l'algorithme de descente du gradient et la méthode des contours actifs afin de détecter les contours de l'objet.

Nous proposons une nouvelle méthode qui étend celle proposée par Bouezrmani et al. [Bouezrmani et al. 2010] dans l'étude de l'estimation non paramétrique des copules de Bernstein. Les densités de probabilité des distributions marginales sont estimées de façon paramétrique alors que l'estimation de la densité s'appuie sur la décomposition sur une base de fonctions orthonormées proposée en 2009 par Wenhao Gui [Gui 2009]. Cette base construite à

partir des polynômes de Legendre est à support sur l'intervalle unité. Notre approche présente les avantages suivants :

- 1) L'utilisation des polynômes orthogonaux permet de résoudre efficacement le problème des effets de bords ce qui réduit la complexité des algorithmes à mettre en œuvre [Gui 2009].
- 2) Il n'est plus nécessaire d'évaluer le paramètre de lissage contrairement aux approches à l'aide des noyaux de Parzen et Rozenblatt .

Le paragraphe suivant propose une étude détaillée de l'estimation de la densité de la copule.

5.3.2. Estimation de la densité de la copule à l'aide des polynômes orthogonaux

Nous nous limitons dans ce qui suit au cas des copules bivariés. Nous allons étudier l'estimation non paramétrique de ces copules bivariées à l'aide d'une famille de polynômes orthogonaux.

Soit une base orthonormée $\Phi = (\varphi_i), i \in \mathbb{N}$ de fonctions de carré intégrable sur l'intervalle unité $L^2([0; 1])$. Définissons le produit tensoriel sur l'espace euclidien $L^2([0; 1]) \times L^2([0; 1])$. par :

$$\forall (x, y) \in [0, 1] \times [0, 1]$$

$$(\varphi_i \otimes \varphi_j)(x, y) = \langle \varphi_i(x), \varphi_j(y) \rangle$$

$$= \iint_{[0;1] \times [0;1]} \varphi_i(x) \varphi_j(y) dx dy = \int_{[0;1]} \varphi_i(x) dx \int_{[0;1]} \varphi_j(y) dy \quad (5.17)$$

Plus généralement, soit une suite (X_n, Y_n) une suite de variables aléatoires continues identiquement distribuées associées à la mesure de probabilité P , et dont $F(\cdot)$ et $G(\cdot)$ sont les fonctions de répartition. Soit C la copule vérifiant la relation suivante :

$$C(F(x), G(y)) = P\{X \leq x, Y \leq y\} = H(x, y) \quad (5.18)$$

pour tout nombre réel x et y dans l'intervalle unité. Si nous supposons que $c(\cdot, \cdot)$ la fonction de densité de la copule C existe, alors elle est définie [Gui 2009] de la façon suivante :

$$c(u, v) = \sum_{i=0}^{\infty} \sum_{j=0}^{\infty} \theta_{ij} \varphi_i(u) \varphi_j(v) \quad (5.19)$$

avec les coefficients

$$\theta_{i,j} = \langle c, \varphi_i \otimes \varphi_j \rangle = E_{\varphi_i}(F(X))E_{\varphi_j}(G(Y)) = \iint_{[0;1] \times [0;1]} \varphi_i(F(x))\varphi_j(F(y))dxdy \quad (5.20)$$

Sous les hypothèses de convergence de la série, une approximation de la formule de la densité de la copule est donnée par :

$$c^*(u, v) = \sum_{i=0}^d \sum_{j=0}^d \theta_{ij}^* \varphi_i(u) \varphi_j(v) \quad (5.21)$$

dans laquelle d est appelé le coefficient de troncature ou «cutoff» dans la littérature anglaise.

Un résultat important est que :

$$\|c^*(u, v)\|^2 = \langle \sum_{i=0}^d \sum_{j=0}^d \theta_{ij}^* \varphi_i(u) \varphi_j(v), \sum_{i=0}^d \sum_{j=0}^d \theta_{ij}^* \varphi_i(u) \varphi_j(v) \rangle = \sum_{i=0}^d \sum_{j=0}^d \theta_{ij}^{*2} \quad (5.22)$$

En nous ramenant à une discrétisation des formules, nous avons finalement une approximation de la densité de la copule donnée par la formule suivante :

$$\hat{c}(u, v) = \sum_{i=0}^d \sum_{j=0}^d \hat{\theta}_{i,j} \varphi_i(u) \varphi_j(v) \quad (5.23)$$

avec φ_i, φ_j , les polynômes de Legendre de degré respectifs i et j ($i, j \leq d$).

L'estimation numérique des coefficients $\hat{\theta}_{i,j}$ est définie de la façon suivante :

$$\hat{\theta}_{i,j} = \frac{1}{N} \sum_{k=1}^N \varphi_i(F_N(X_k)) \varphi_j(G_N(Y_k)) \quad (5.24)$$

Dans l'expression (5.14), les fonctions $F_N(\cdot)$ et $G_N(\cdot)$ sont les fonctions de répartition des variables aléatoires marginales estimées de façon paramétrique. La convergence en loi de la variable $\sqrt{n} (\hat{\theta}_{i,j} - \theta_{i,j}^*)$ vers la loi normale $\mathcal{N}(0, \sigma_{i,j}^2)$ est assurée sous la condition de Mild appliquée au produit $\varphi_i \varphi_j$ [Gui 2009]. Un estimateur de la variance est donné par [Gui 2009] :

$$\hat{\sigma}^2 = \frac{1}{N} \sum_{i=1}^N (W_i - \bar{W})^2 \quad (5.25)$$

avec

$$W_i = \phi(F_N(X_i))\psi(G_N(Y_i)) + \frac{1}{N} \sum_{j=1}^N \phi'(F_N(X_i))\psi(G_N(Y_j)) + \frac{1}{N} \sum_{j=1}^N \phi(F_N(X_i))\psi'(G_N(Y_j)), 1 \leq i \leq N, \quad (5.26)$$

Les fonctions ϕ et ψ sont les polynômes de Legendre et \bar{W} est la moyenne empirique sur les N échantillons.

Dans notre approche nous allons nous intéresser à la famille des polynômes de Legendre qui sont les plus simples des polynômes orthogonaux. Nous utiliserons une version tronquée à l'intervalle unité de ces polynômes car nous désirons obtenir une base de fonctions orthonormées et de carré intégrables à support dans l'intervalle unité. Pour ce faire, nous allons modifier la formule de Rodrigues générale des polynômes de Legendre [Lavoie 2015, Ludovic 2000]

$$\varphi_n(x) = \frac{1}{w(x)} \frac{d^n}{dx^n} [(1-x^2)^n w(x)] \quad (5.27)$$

dans laquelle $\varphi_n(x)$ est un polynôme de Legendre de degré n , avec $n \in \mathbb{N}$

La fonction $w(\cdot)$ est telle que si on se donne un intervalle $[a; b] \subset \mathbb{R}$, $w(x) > 0$ et on a $\int_a^b x^n w(x) dx$ La fonction $w(x)$ est appelée fonction de poids

Cette modification vise à proposer une restriction des polynômes de Legendre à l'intervalle unité.. Cette formule devient alors (avec 0 et 1 comme racines du polynôme de Legendre de degré n) :

$$\varphi_n(x) = \frac{1}{w(x)} \frac{d^n}{dx^n}$$

La figure 5.1 montre la chaîne originale (a), sa version bruitée (b), la version estimée à partir des vrais paramètres (c), le résultat de la segmentation avec une CMCo gaussienne classique avec sélection automatique de la copule de façon paramétrique (CMCo-SAC) (d), (e) le résultat obtenu par une chaîne de Markov cachée à bruit Indépendant (CMC-BI) et (f) le résultat obtenu par la nouvelle approche que nous proposons qui est une chaîne de Markov couple avec copule non paramétrique (CMCO-CNP).

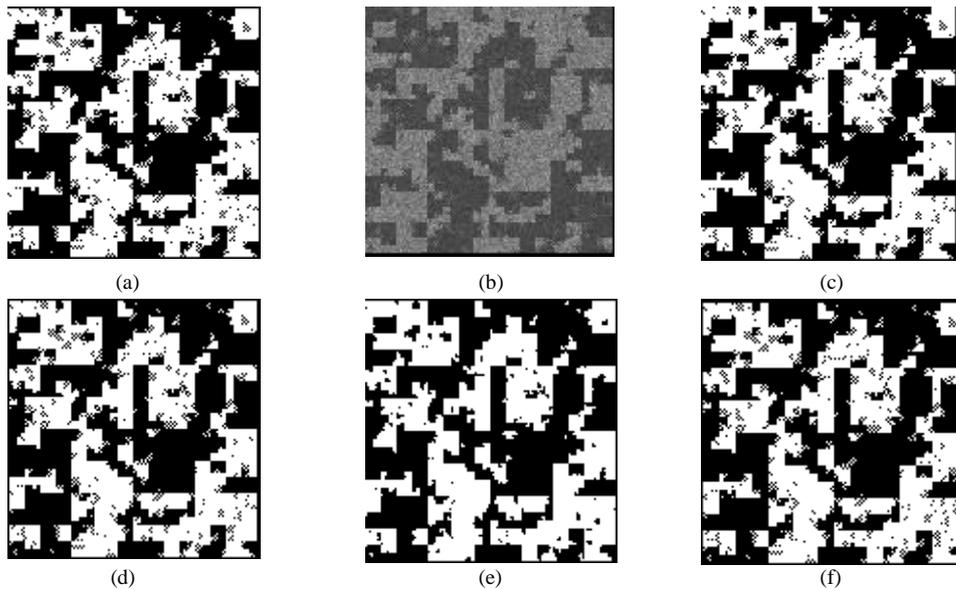


Figure 5. 4 Segmentation semi supervisée d'une chaîne de Markov couple simulée ; (a) Chaîne de Markov couple, (b) Version bruitée, (c) Estimation par les vrais paramètres, (d) CMCo-SAC, (e) CMC-BI, (f) CMCo-CNP

Les résultats de la restauration des paramètres que sont la moyenne et la variance des marginales pour la chaîne de Markov couple avec sélection automatique de la copule et la chaîne de Markov couple avec copule non paramétrique sont donnés dans le tableau 5.2

Tableau 5. 2 Moyennes et variances des marginales estimées par les algorithmes des Chaines de Markov Couple avec sélection automatique de la copule et à partir de la méthode des polynômes

		Vrais paramètres	CMCo-SAC	CMCo-CNP
i=1	$f_{1,1}$	$\mu = 124.562$	$\mu = 124.588$	$\mu = 124.573$
j=1		$\sigma = 15.757$	$\sigma = 16.553$	$\sigma = 16.551$
i=1	$f_{1,2}$	$\mu = 75.550$	$\mu = 74.221$	$\mu = 74.256$
j=2		$\sigma = 7.732$	$\sigma = 8.754$	$\sigma = 8.723$
i=2	$f_{2,1}$	$\mu = 102.803$	$\mu = 101.104$	$\mu = 101.108$
j=1		$\sigma = 15.324$	$\sigma = 16.529$	$\sigma = 16.384$
i=2	$f_{2,2}$	$\mu = 74.398$	$\mu = 74.493$	$\mu = 74.4975$
j=2		$\sigma = 7.070$	$\sigma = 6.866$	$\sigma = 6.859$

Comme présentés dans le tableau 5.2, les paramètres des marginales sont assez proches de ceux qui ont contribué à simuler la chaîne de Markov couple. Les erreurs de calcul de la moyenne sont assez proches dans le cas des deux algorithmes avec sélection automatique de la copule et avec polynômes de Legendre. Cependant notre modèle estime mieux les paramètres de la variance. Comme illustré dans le tableau 5.2, le nouvel algorithme donne des valeurs de variance inférieures à celles obtenues par le modèle avec sélection automatique de la copule. Ce qui indique que les valeurs estimées dans nos différentes expériences sont réparties dans un voisinage assez proche de la valeur moyenne estimée, contrairement au modèle avec sélection automatique de la copule. Cela prouve la stabilité de l'algorithme proposé et laisse suggérer que notre algorithme préserve le pouvoir de restauration des chaînes de Markov couple en présence de bruit. Les taux moyens d'erreur obtenus au terme de nos expériences montrent une meilleure restauration face au modèle des chaînes de Markov avec sélection automatique et est une alternative intéressante au problème de la modélisation de la copule.

Dans une deuxième série d'expériences, nous avons montré la robustesse de notre approche en présence d'un bruit corrélé à moyenne mobile. Les paramètres du bruit sont donnés par la formule suivante : $y_n = x_{n-1} + \delta_{\omega_1}(x_n) + \alpha[\epsilon_{n-1} + \epsilon_n]$ (5.47) dans laquelle $\delta_{\omega_1}(x_n) = 1$ si $x_n = \omega_1$ et $\delta_{\omega_1}(x_n) = 0$ sinon et les ϵ_n sont des lois normales $N(0,1)$ indépendantes avec $\alpha = 0.6$. Le nombre d'itérations est fixé à 60 car comme l'a montré Pieczynski et Benmiloud [Pieczynski et Benmiloud 1995], la segmentation des images à l'aide des modèles markoviens des images bruitées avec du bruit à moyenne variable convergent rapidement (20 itérations en moyenne suffisent pour obtenir un résultat satisfaisant). La comparaison des résultats de notre algorithme et du modèle de sélection automatique de copule est effectuée pour une segmentation à deux classes d'une image de synthèse de taille 128×128 pixels. La figure 5.2 suivante présente l'image originale et sa version bruitée par le bruit corrélé ainsi que les résultats de la segmentation par Chaînes de Markov Couple.

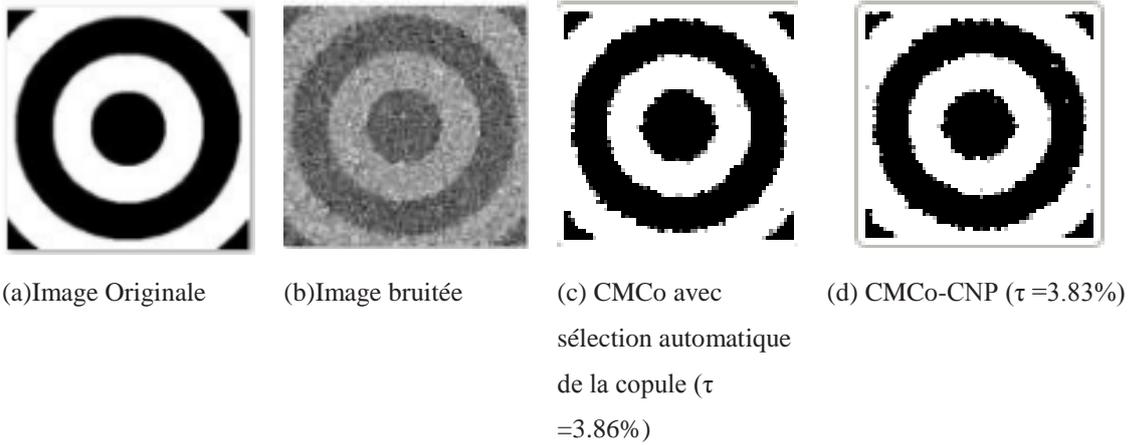


Figure 5. 5 Image de synthèse originale et bruitée ainsi que les versions obtenues après segmentation par chaînes de Markov Couple

Ces résultats montrent que dans les conditions de l'expérience, notre algorithme donne de bonnes performances puisque les taux d'erreurs obtenus (3.83 %) sont assez semblables à ceux obtenus par sélection automatique de la copule (3.86 %). Cela démontre le pouvoir de restauration et de sélection de la copule face à du bruit corrélé autorégressif.

Dans la troisième série d'expériences, nous soumettons notre algorithme à la segmentation de deux images ; l'image Nazca de taille 128×128 pixels (Figure 5.3.a) et l'image zèbre de taille 256×256 pixels (Figure 5.4.a). Ces images sont bruitées par l'intermédiaire d'un bruit non stationnaire fortement corrélé (Figure 5.3.b) et faiblement corrélé (Figure 5.4.b). La formule de l'image bruitée dans le cas de l'image Nazca est donnée par :

$$Y_s = \sigma_{x_s} W_s + \mu_{x_s} + 0.25 \sum_{i=1}^4 (\sigma_{x_{s_i}} W_s + \mu_{x_{s_i}}) \quad (5.48)$$

avec W_s un bruit gaussien normal centré de variance 1, s_i , le pixel du voisinage d'ordre 4 du pixel s avec $i = 1,2,3,4$. Nous supposons que $\sigma_{x_{s_1}} = 1, \sigma_{x_{s_2}} = 2, \mu_{x_{s_1}} = 0, \mu_{x_{s_2}} = 3$.

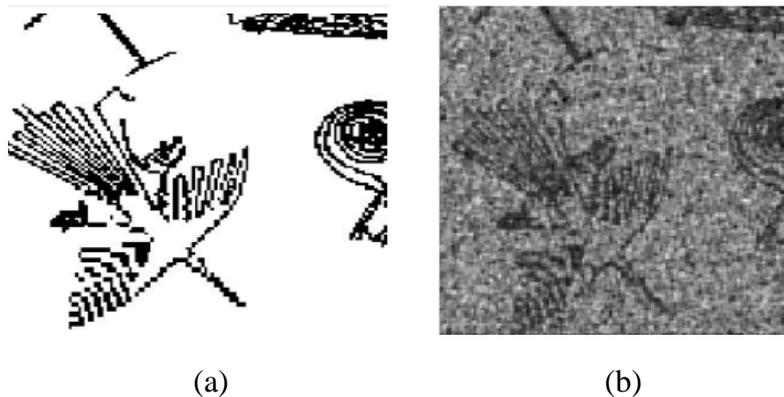
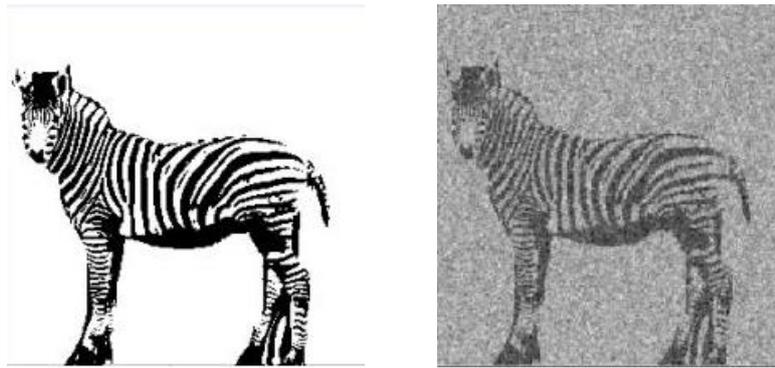
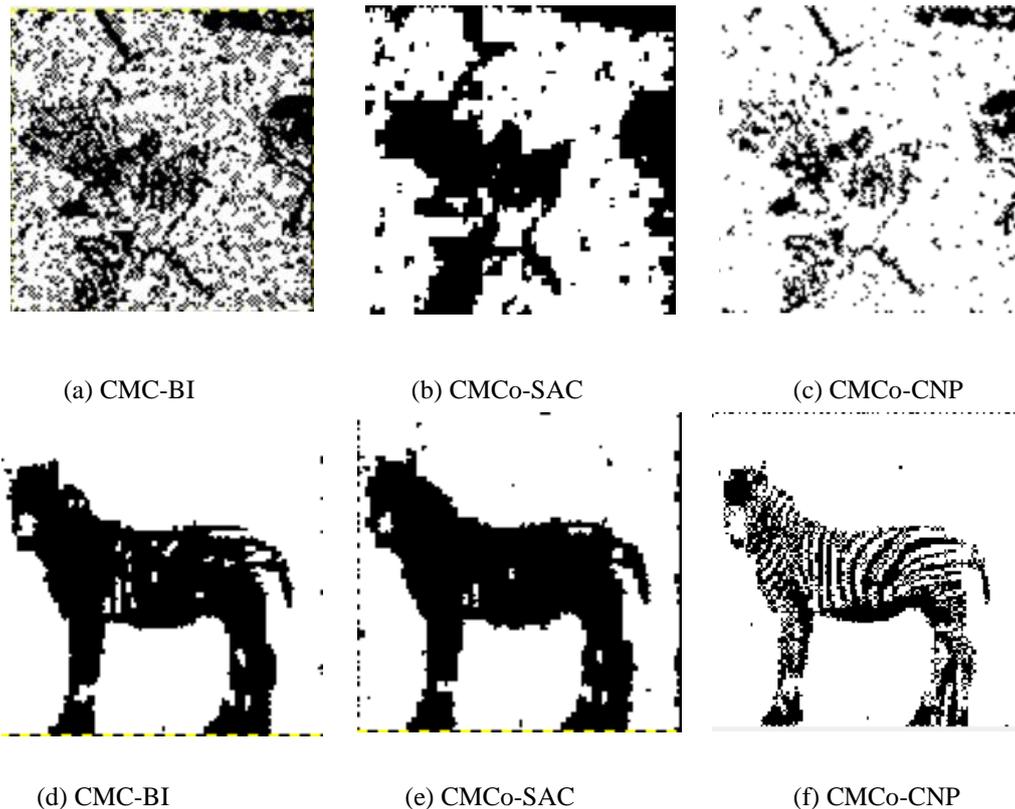


Figure 5. 6 Image Nazca et sa version bruitée



(a) (b)
Figure 5. 7 Image Zebre et sa version bruitée

La figure 5.5 montre les résultats obtenus par notre algorithme et l'algorithme des chaînes de Markov classiques et celui de la sélection automatique des copules proposé par Derrode et Pieczynski en 2013 [Derrode et Pieczynski 2013, Derrode et Pieczynski 2016].



(a) CMC-BI (b) CMCo-SAC (c) CMCo-CNP
(d) CMC-BI (e) CMCo-SAC (f) CMCo-CNP
Figure 5. 8 Résultats de la segmentation par différents algorithmes de chaînes de Markov de l'image Nazca et Zebre

Une analyse visuelle nous montre que contrairement aux deux algorithmes précédents, le modèle proposé conserve mieux les formes et les contours. L'algorithme CMC-BI fournit l'image la plus bruitée (cf. tableau 5.3) alors que le modèle avec sélection automatique de la

copule par approche paramétrique fournit l'image la moins bruitée mais dégrade davantage les contours des images. Les taux d'erreur calculés (cf. tableau 5.3) pour les différents algorithmes pour une série de 20 expériences confirment les premiers résultats de l'analyse visuelle. Les taux d'erreur moyens du modèle couple avec sélection automatique de la copule s'expliquent par le fait que la dépendance ne peut être modélisée par aucune des familles de copules données car ce modèle est construit sur l'hypothèse que les copules appartiennent à une famille bien définie [Derrode et Pieczynski 2013]. Quant au modèle à bruit indépendant, l'hypothèse d'indépendance des observations limite la capacité de segmentation du signal lorsque le bruit est corrélé. Ce phénomène induit en effet une dépendance entre les données observées.

Tableau 5. 3 Taux d'erreur comparés entre différents algorithmes de segmentation

Algorithmes	Image Nazca Taux d'erreur (%)	Image Zebre Taux d'erreur (%)
Algorithme proposé (CMCo-CNP)	10.3%	8.82 %
Chaine de Markov Cachée (CMC-BI)	45.7%	15.97%
CMCO avec selection automatique de la copule (CMCo-SAC)	12.8%	14.04%

5.7. Analyse et évaluation des résultats sur des images réelles

Ce dernier paragraphe est consacré à l'application à des cas pratiques du nouvel algorithme construit tout au long des chapitres précédents afin de bâtir le masque de changement. Comme indiqué dans le chapitre 1, l'avènement des imageurs à THRS a entraîné la multiplicité des images disponibles pour l'étude d'une même zone géographique. Toute méthode d'analyse d'image développée doit être en mesure de pouvoir s'adapter à cet état de fait. Le chapitre se décompose de la façon suivante. Dans la section 5.7.1 nous étudions le comportement de notre algorithme face à des images issues d'un même senseur optique. La section 5.7.2 est quant à elle dédiée à l'évaluation de la performance de notre méthode face à des images hétérogènes mais provenant de deux senseurs de même famille, notamment des senseurs optiques. Nous terminerons notre phase d'évaluation des performances par un cas très courant dans la pratique à savoir celui de deux senseurs dont l'un est de type optique et l'autre de type radar imageur dans la section 5.7.3. Notre algorithme sera comparé aux mesures classiques à base statistique notamment le coefficient de corrélation linéaire (CC) et l'information mutuelle (IM) grâce au

ROC estimé sur notre algorithme de classification. Les expériences ont été menées sur un ordinateur de type PC doté d'un processeur Core i5 et 4 Go de RAM.

5.7.1. Cas de deux images acquises par le même capteur

Nous allons dans cette expérience, tester notre algorithme face à deux images optiques issues du satellite QuickBird. Ces images présentent une zone côtière affectée par une catastrophe naturelle. La zone d'étude, pour cette première expérience est une des côtes de l'Indonésie frappée par le tsunami de 2004. Ces images présentées aux figures 5.6.a et 5.6.b sont le résultat de la fusion d'une image panchromatique à la résolution spatiale de 60 cm et d'une image multispectrale acquise dans les 3 bandes spectrales du visible et du proche infrarouge. L'image de référence ou image « Référence » a été acquise en Avril 2004 tandis que l'image de changement encore appelée image « Changement » a été acquise en Janvier 2005 par le satellite QuickBird. Ces images sont issues de [Wu et al. 2012]. Les images ont une taille de 3217×4231 pixels. Une image vérité terrain fournie par un photo- interprète est également disponible (Figure 5.6.c). Comme on peut le voir visuellement les deux images montrent des différences notables surtout en bordure du littoral où l'on peut observer les effets du tsunami. Dans cette image binaire les zones en rouge représentent les zones de changement.



(a)



(b)



(c)

Figure 5. 9 Images tests acquises par le satellite QuickBird (a) Avril 2004 (b) Juin 2005 (c) Vérité terrain
(Source : [Wu et al. 2012])

Afin de prouver l'efficacité de la méthode proposée, les résultats obtenus ont été comparés à ceux des deux principaux opérateurs rencontrés dans la littérature scientifique à savoir le coefficient de corrélation linéaire (CC) et l'information mutuelle (IM). Pour nos expériences, nous avons choisi des voisinages de taille 20×20 pixels contre des voisinages de taille 50×50 pixels pour le coefficient de corrélation linéaire et l'information mutuelle. Une segmentation par superpixels a été d'abord appliquée à nos deux images. Elle nous a permis d'obtenir un nombre d'objets compris dans l'intervalle $[1, 10]$ par fenêtre d'études. Le choix de la taille de fenêtre de 50×50 pixels pour le CC et l'IM se justifie par le fait que pour se montrer efficace, ces opérateurs nécessitent un nombre suffisant d'échantillons afin de pouvoir évaluer correctement les résultats. Quant à notre approche, le choix de la fenêtre s'est effectuée suite à différentes expériences menées avec différentes tailles de fenêtres qui ont donné les meilleurs résultats pour des fenêtres de taille 10×10 pixels. En ce qui concerne les algorithmes CC et IM, ils ont été directement appliqués sur les images « Before » et « After ». Il est à noter que les résultats obtenus par les différentes mesures de similarité (voir figure 5.7) ont par la suite été régularisées par notre algorithme des chaînes de Markov couple. Les temps moyens d'exécution des algorithmes ont été de 2 mn 30s pour le coefficient de corrélation et l'Information Mutuelle alors que, notre algorithme a nécessité un temps moyen de 5 h 21 mn.

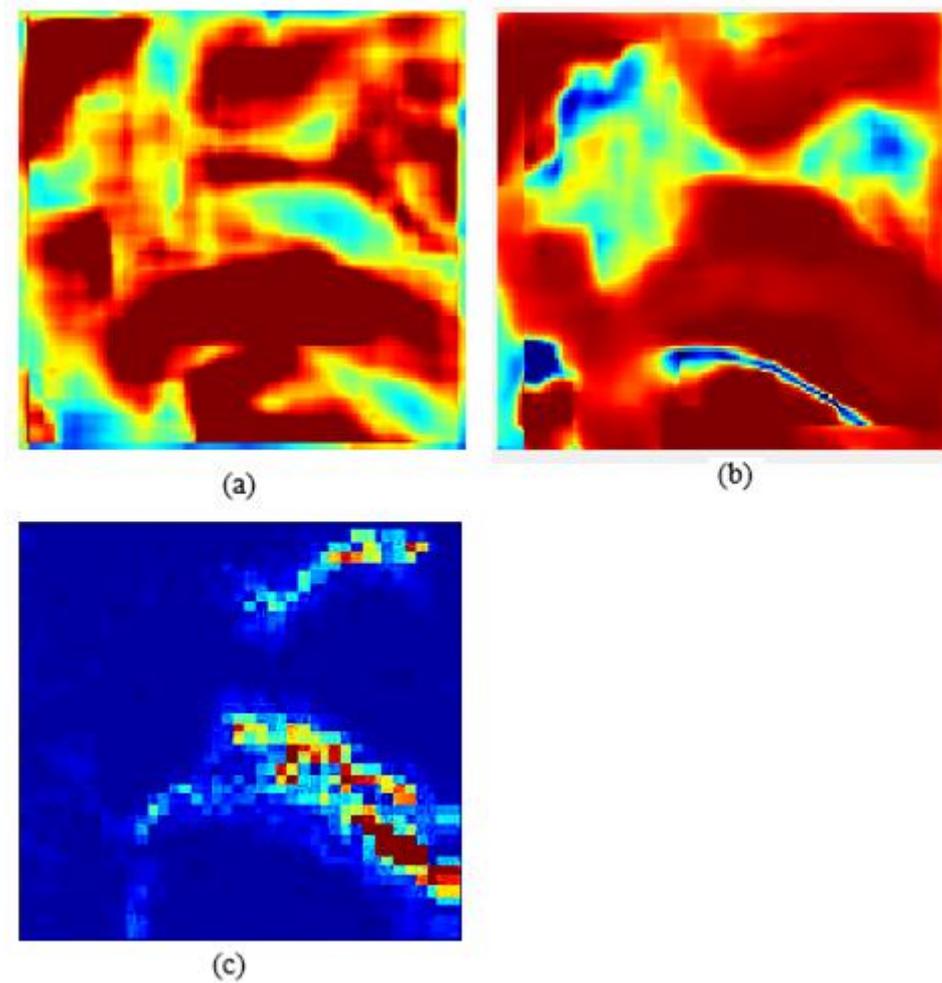


Figure 5. 10 Mesures de similarités pour différents algorithmes (a) Coefficient de corrélation linéaire (b) Information mutuelle (c) Notre modèle

La figure 5.8 donne la courbe ROC pour les différentes mesures de similarité. Le niveau de détection du taux d'erreur est donné par le point d'intersection de la courbe ROC et de la droite d'équation $1 - PFA$. Le tableau 5.4 fournit les taux d'erreurs obtenus pour les différents algorithmes.

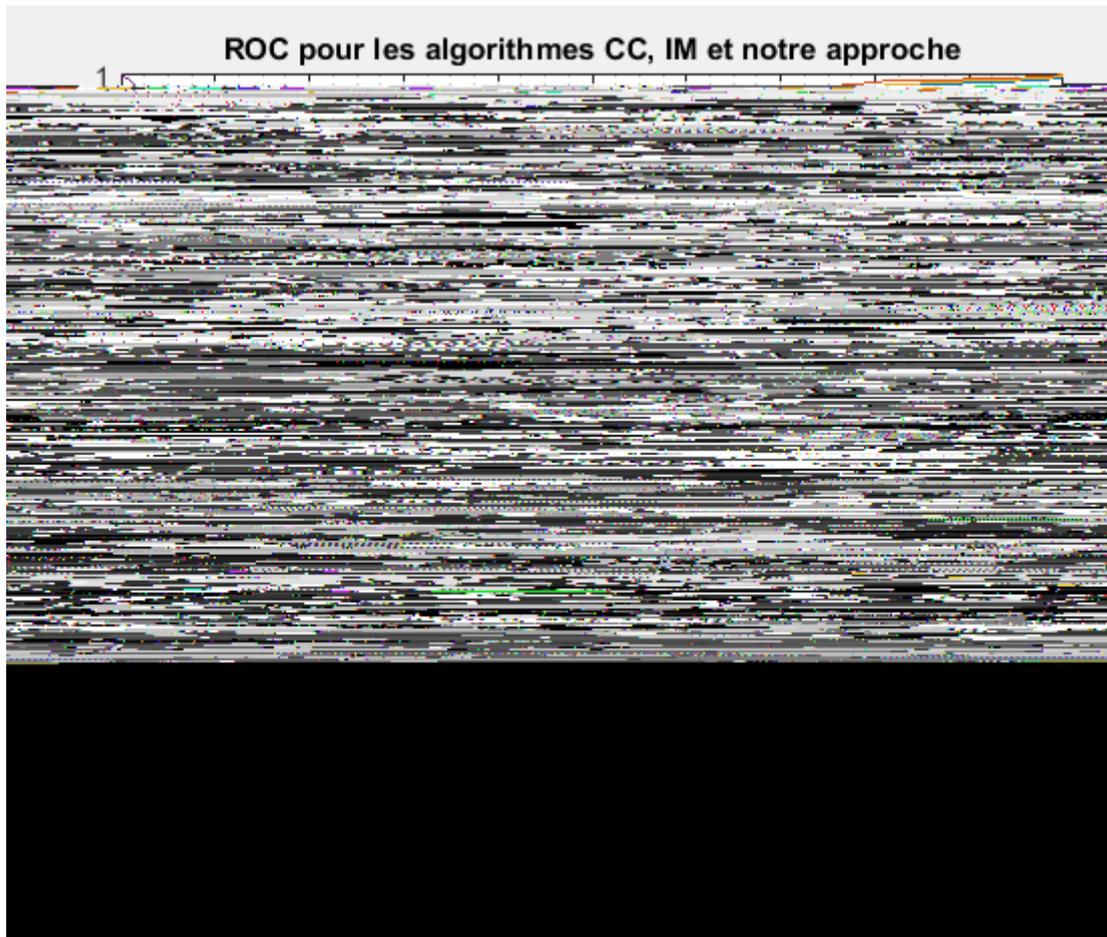


Figure 5. 11 Courbe ROC pour l'évaluation des performances de différents algorithmes

Tableau 5. 4 Taux d'erreur pour différentes mesures de similarité des images de la figure 5.6

Algorithme	Taux d'erreur (%)
Coefficient de corrélation linéaire (CC)	13.5 %
Information mutuelle (IM)	13.3 %
Notre méthode	12.4 %

Notre méthode fournit un taux d'erreur de 12.48% comparativement à un taux d'erreur de 13.3 % pour l'information mutuelle et un taux d'erreur de 13.5% pour le coefficient de corrélation linéaire. Il est à noter que bien que notre algorithme donne les meilleurs résultats, les valeurs obtenues par le CC et l'IM sont relativement proches puisque nos images sont composées de grandes zones homogènes (zone centrale inchangée et deux zones changées en rouge dans l'image de référence). Dans ce cas, comme l'a montré Prendes dans [Prendes 2015], la dépendance est modélisée par une fonction affine. Cela permet au coefficient de corrélation

linéaire d'obtenir des résultats assez proches de l'information mutuelle et de notre algorithme même s'il est moins performant à modéliser les dépendances non linéaires présentes surtout dans les zones changées que notre algorithme.

5.7.2. Cas de deux images acquises par des senseurs optiques différents

Dans cette section, nous allons étudier les performances de notre algorithme pour deux images de type optiques mais acquises par deux senseurs différents. Il s'agit de deux images acquises l'une par le satellite Pleiades et l'autre par le satellite GeoEye 1 qui fournit les images de Google Earth. Ces images sont extraites de [Prendes 2015]. Elles représentent l'évolution d'une zone urbaine du sud de la ville de Toulouse en France marquée par l'apparition de nouvelles constructions. L'image figure 5.9.a est une image multispectrale à très haute résolution spatiale qui est le résultat de la fusion de l'image panchromatique à la résolution de 50 cm et de l'image multispectrale à 4 bandes (R,V,B, NIR) à la résolution de 2 m. L'image Google Earth (figure 5.9. b) est une image multispectrale à 3 bandes (Rouge, Vert, Bleu) redimensionnée pour obtenir une résolution spatiale de 50 cm. Les 2 images ont une taille de 2000×2000 pixels. Un modèle vérité terrain (figure 5.9.c) est également disponible.

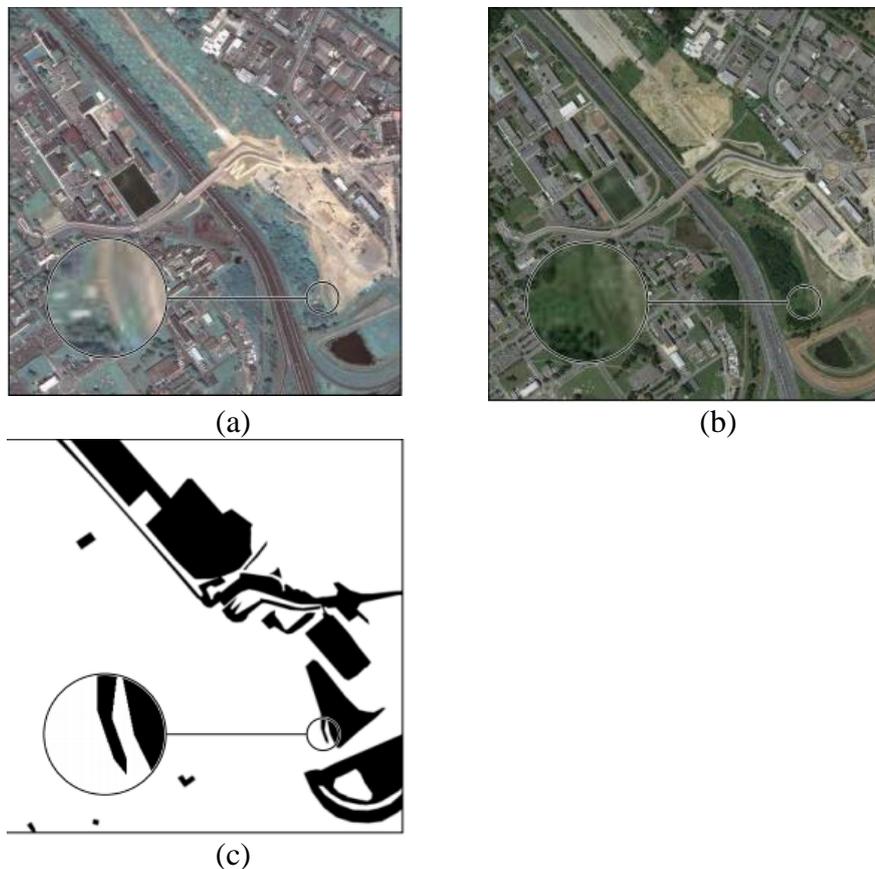


Figure 5. 12 Images tests acquises par les satellites Pleiades et Geo Eye (a) Pléiades - Mai 2012 (b) GeoEye 1 - Juin 2013 (c) Vérité terrain (Source : [Prendes 2015])

Comme dans le premier cas, la nouvelle mesure de similarité est évaluée face aux mesures de similarité classiques telles que le coefficient de corrélation linéaire (CC) et l'information mutuelle (IM). La figure 5.10 suivante illustre les résultats obtenus pour notre méthode et les différents algorithmes classiques. Le choix des fenêtres respecte celui fait dans la section précédente. Les temps d'exécution vont de 3 mns 10 s pour le coefficient de corrélation à 5 mns 21 s pour l'Information Mutuelle et 5 h 53 mns pour notre algorithme.

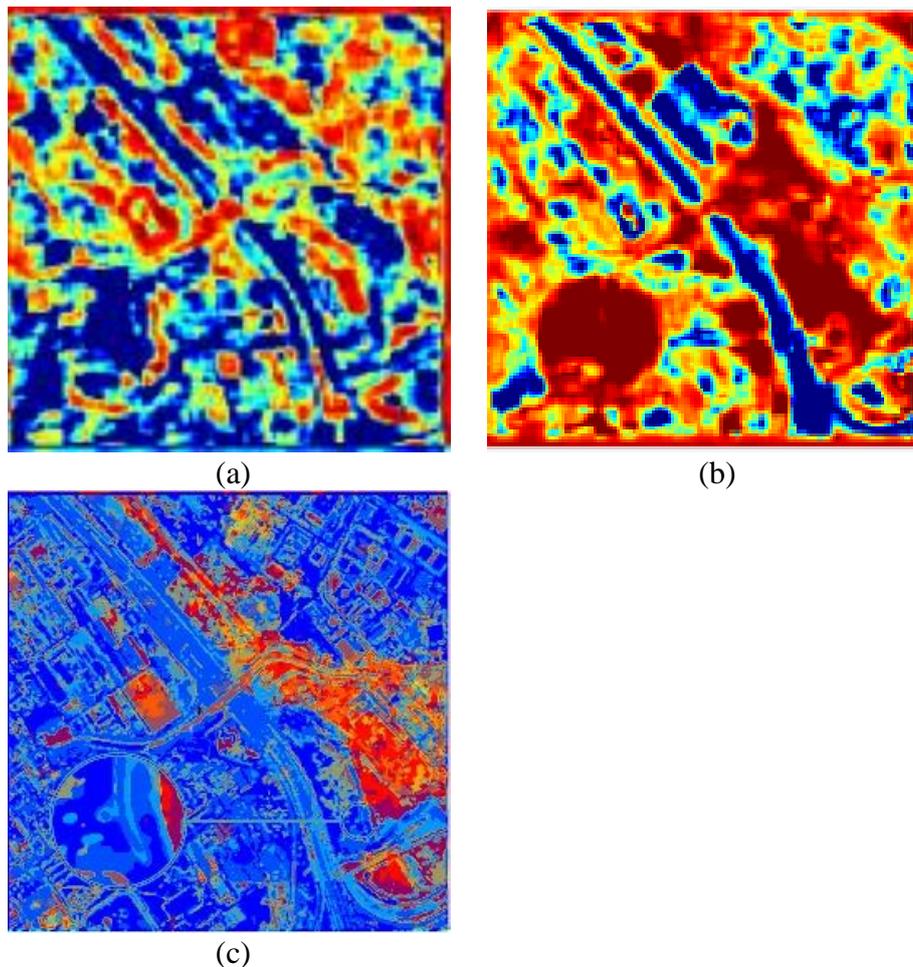


Figure 5. 13 Mesures de similarités pour différents algorithmes (a) Coefficient de corrélation linéaire (b) Information mutuelle (c) Notre modèle

La figure 5.11 présente la courbe ROC obtenue pour nos différents algorithmes lorsqu'ils sont classifiés par notre nouveau classifieur markovien. Le tableau 5.5 présente les différents taux d'erreurs obtenus par les différents algorithmes. Les taux d'erreur sont 12% pour notre algorithme contre 24 % pour l'information mutuelle et 26% pour le coefficient de corrélation linéaire. Bien qu'il s'agisse de senseurs de nature optique, il existe une dépendance entre les images qui n'est pas forcément linéaire et que les algorithmes CC et IM ne prennent pas en compte. Ce qui explique les résultats moyens obtenus par ces deux algorithmes.

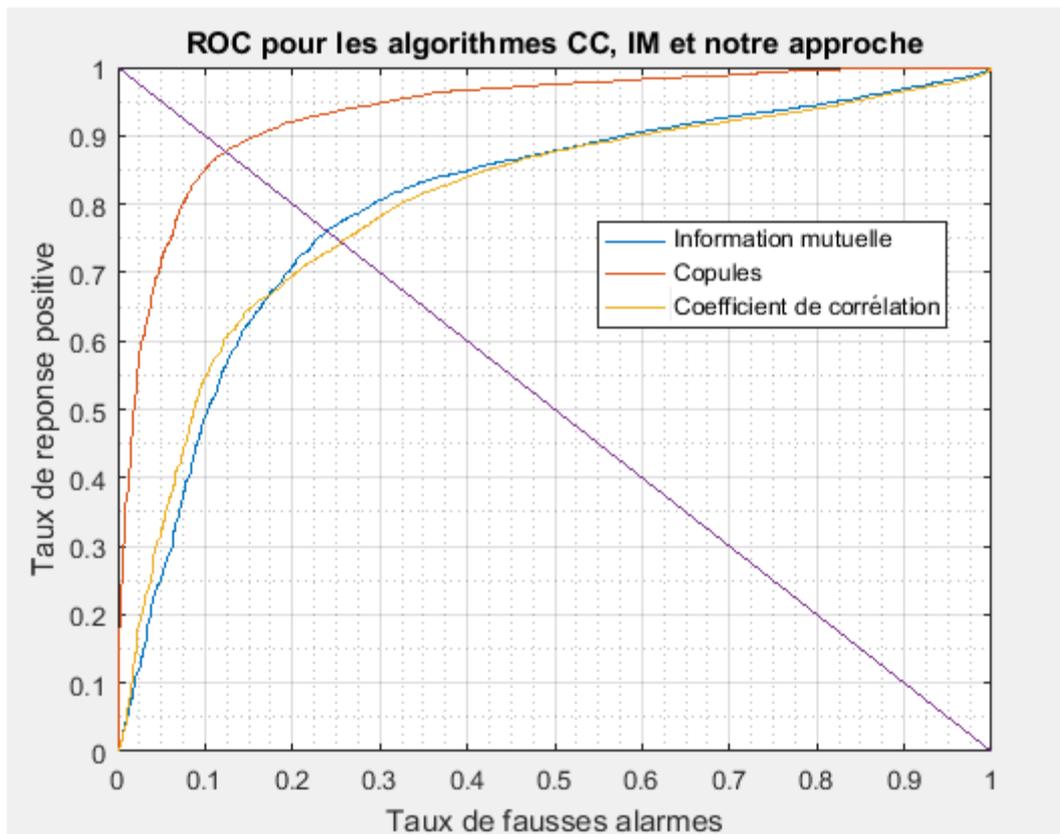


Figure 5. 14 Courbe ROC pour l'évaluation des performances des différents algorithmes

Tableau 5. 5 Taux d'erreur pour différentes mesures de similarité des images de la figure 5.9

Algorithme	Taux d'erreur (%)
Coefficient de corrélation linéaire (CC)	26 %
Information mutuelle (IM)	24 %
Notre méthode	12 %

5.7.3. Cas de deux senseurs hétérogènes

Cette dernière section présente un cas rencontré dans la pratique qui est celui de la détection des changements dans le cas de deux senseurs hétérogènes, un optique et l'autre radar, lors de l'étude des effets d'une catastrophe naturelle. Les images sont extraites de [Prendes 2015]. Ces images présentent une image mixte composée d'une zone urbaine et d'une zone rurale du Sud de Gloucester marquée par une inondation. L'image référence est une image optique multispectrale en 3 canaux (Rouge, vert, Bleu) fournie par Google Earth (figure 5.12.a) et l'image changement ou image « After » (figure 5.12.b) est acquise par le radar imageur

TerraSAR-X à une résolution spatiale de 7.3 m. Les images ont une taille originale de 3217×1024 pixels. Un modèle vérité terrain fourni par un expert est également disponible (figure 5.12.c)

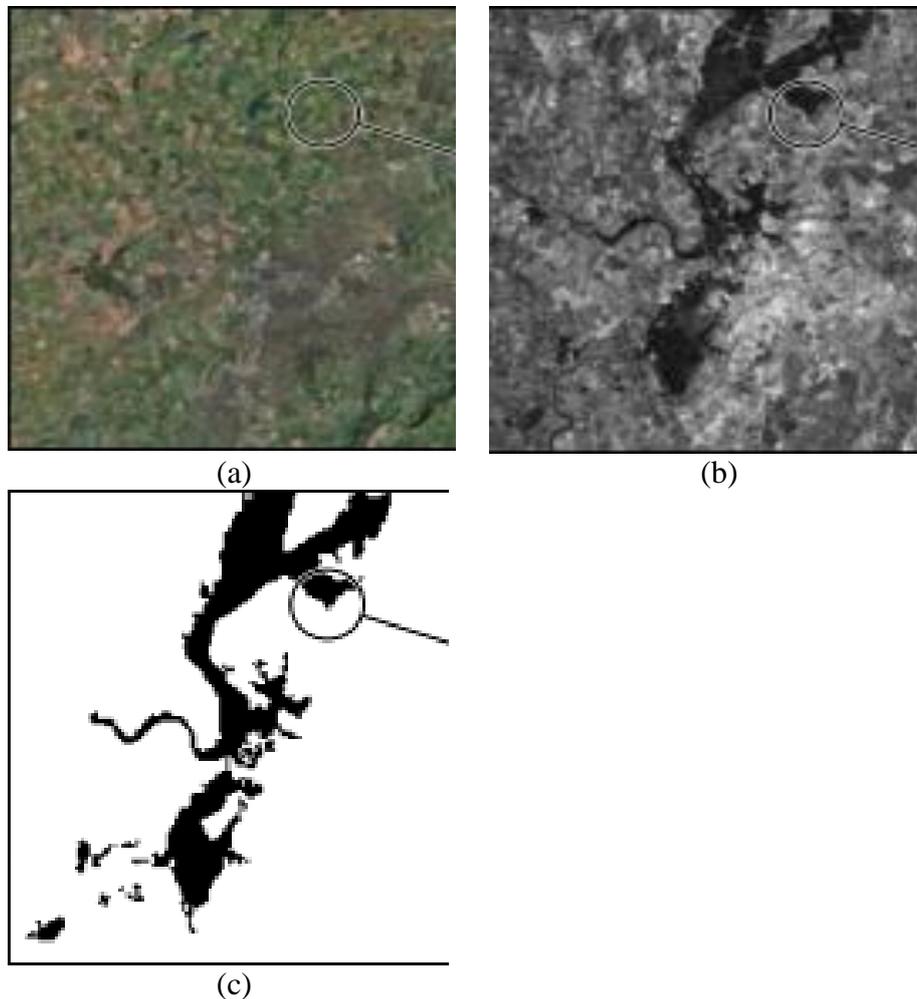


Figure 5. 15 Images tests acquises par les satellites Geo Eye et TerraSAR-X (a) Geo Eye – Dec. 2006 (b) TerraSAR-X – Jul. 2007 (c) Vérité terrain (Source : [Prendes 2015])

Nous avons évalué notre algorithme face aux mesures de similarité classiques que sont le coefficient de corrélation linéaire (CC) et l'information mutuelle (IM). Nous avons utilisé comme précédemment des fenêtres recouvrantes de 50% de taille 10×10 pixels pour notre algorithme. L'algorithme EM utilisé est construit à partir d'un nombre de composants fixé dans l'intervalle $[1, 10]$ obtenu après segmentation en superpixels. Pour les algorithmes CC et IM des fenêtres de taille 50×50 pixels ont été utilisées. Comme précédemment, les taux d'erreurs ont été évalués à l'aide de la courbe ROC par la détermination du taux de fausses alarmes. La figure 5.13 illustre les images obtenues après application des différentes mesures de similarité.

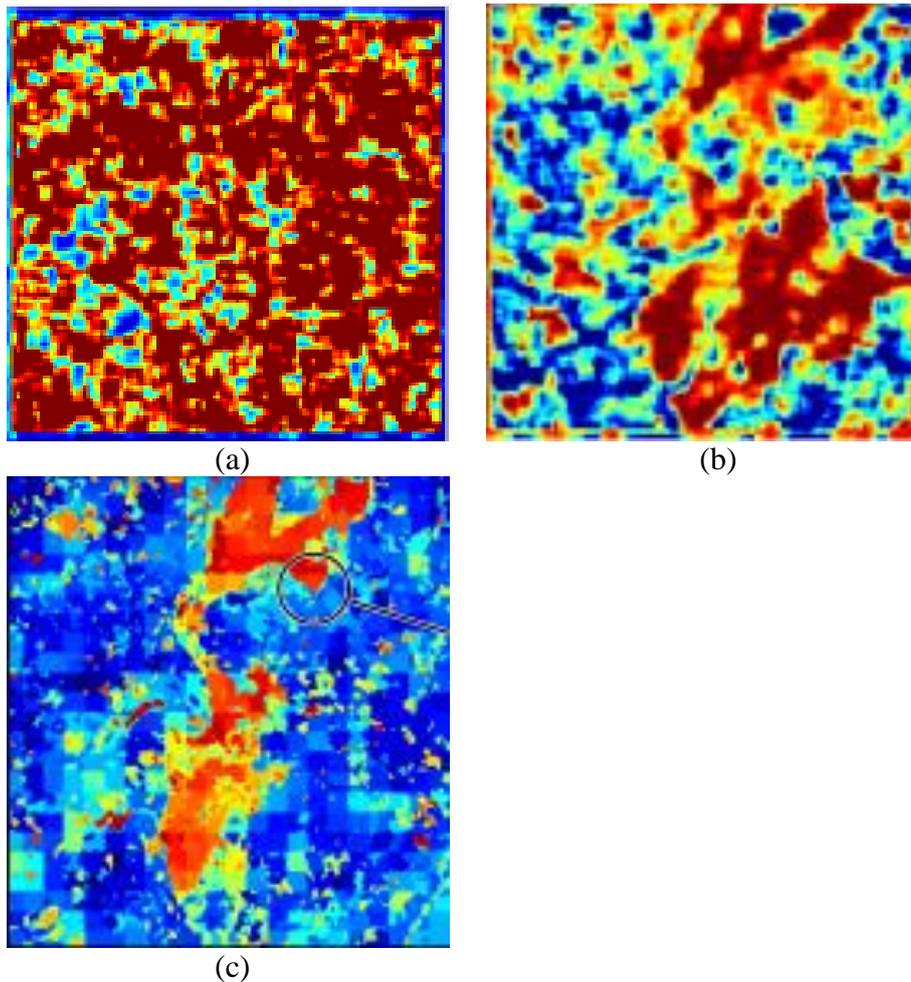


Figure 5. 16 Mesures de similarités pour différents algorithmes (a) Coefficient de corrélation linéaire (b) Information mutuelle (c) Notre modèle

Pour cette troisième expérience, les temps d'exécution obtenus ont été de 3 mns 20 s pour le coefficient de corrélation linéaire, de 12 mns 17 s pour l'Information Mutuelle et de 5 h 32 mns pour notre algorithme.

Une analyse visuelle nous montre déjà que le CC a du mal à discriminer les zones changées (zones en rouge) des zones non changées. Comme nous l'avons indiqué dans le chapitre 2, ces performances sont mauvaises lorsqu'il s'agit de faire ressortir des dépendances non linéaires. De plus, les images de départ sont caractérisées par de fortes variations locales. L'IM quant à lui, caractérise les zones de changements (zones en rouge) mais leurs contours sont bien moins visibles que dans le cas de notre algorithme qui propose une distinction nette entre les zones changées (zones en rouge) et les zones inchangées (zones en bleu).

La courbe ROC (figure 5.14) confirme l'impression visuelle. Les résultats résumés dans le tableau 5.6 montrent que nous obtenons un taux d'erreur de 12.4 % pour notre méthode, contre 28.3 % pour l'information mutuelle et 49.8 % pour le coefficient de corrélation linéaire. Cela

se justifie par le fait que notre méthode modélise les dépendances entre les données contrairement à l'information mutuelle qui suppose une indépendance des observations.

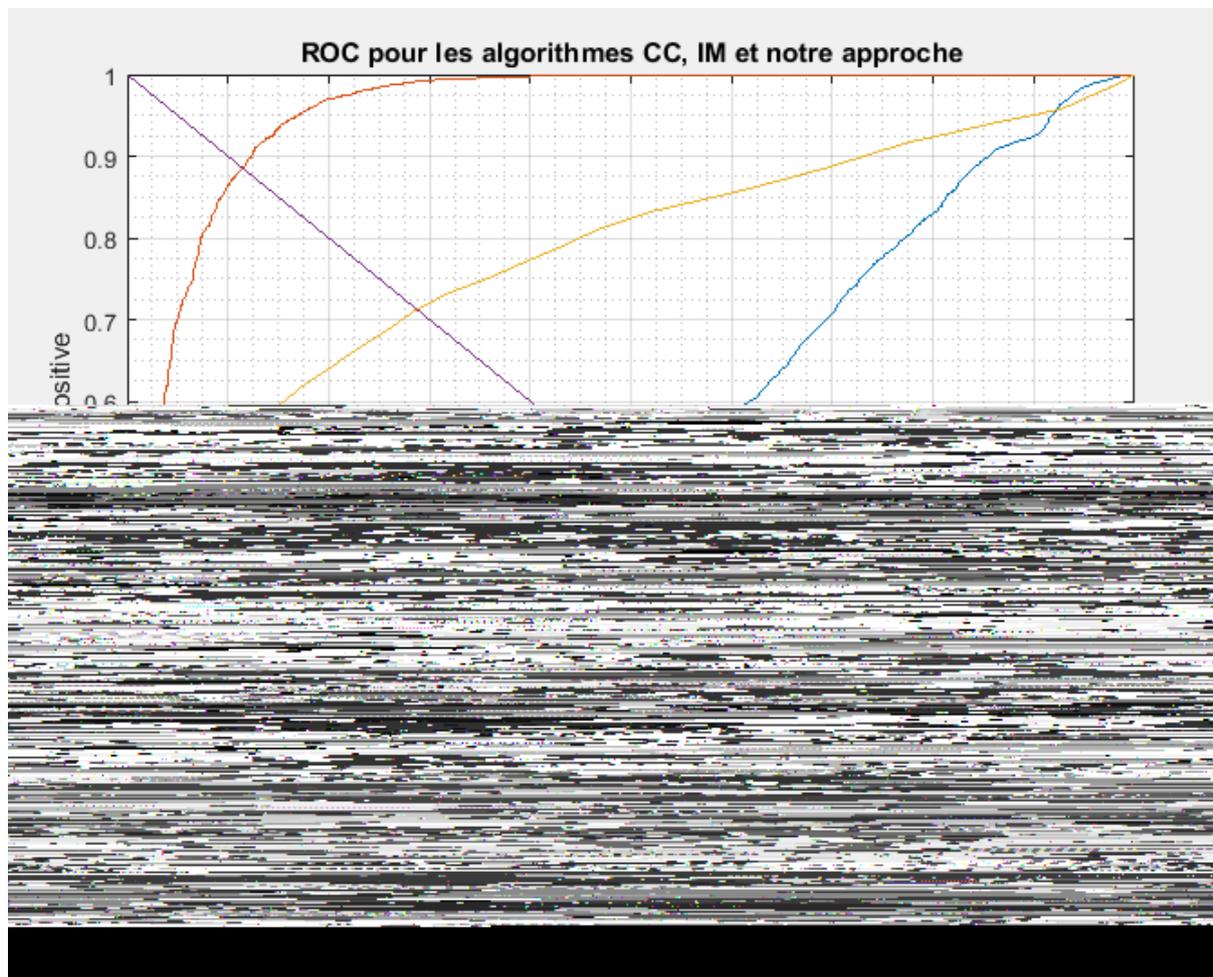


Figure 5. 17 Courbe ROC pour l'évaluation des performances des algorithmes

Tableau 5. 6 Taux d'erreur pour différentes mesures de similarité des images de la figure 5.12

Algorithme	Taux d'erreur (%)
Coefficient de corrélation linéaire (CC)	49.8 %
Information mutuelle (MI)	28.3 %
Notre méthode (copules)	12.4 %

5.8. Conclusion

Dans ce chapitre, nous avons utilisé les chaînes de Markov couple afin de régulariser notre masque de changement obtenu dans le chapitre précédent. Cette régularisation est possible par la prise en compte dans ce modèle de la corrélation spatiale entre les observations. La modélisation utilisée pour cette corrélation spatiale est l'utilisation de la copule qui a montré tout son intérêt pour la caractérisation des dépendances entre données observables. Cette modélisation s'est effectuée de façon non paramétrique à l'aide des polynômes orthogonaux de Legendre restreints à l'intervalle unité afin d'éliminer les effets de bord. Les expériences menées sur des images de synthèse ont montré le pouvoir de classification de la nouvelle approche comparativement aux modèles de la littérature classique surtout en présence de bruit corrélé. Les résultats obtenus sont aussi encourageants même dans le cas les plus défavorables d'images non stationnaires comme c'est le cas pour nos images de synthèse. Ce nouveau modèle va nous servir de classificateur, et va permettre la construction du masque de changement à partir de la matrice de similarité construite dans le chapitre précédent. Les performances de notre modèle ont été validées sur des images réelles dans le cas de capteurs aussi bien homogènes qu'hétérogènes et se sont montrées meilleures que celles obtenues par deux des principales mesures de similarité rencontrées dans la littérature.

Conclusion et perspectives

Conclusion

Ce présent manuscrit a été consacré à la présentation d'une nouvelle méthode de détection automatique des changements dans les images à THRS. Cette nouvelle méthode s'est appuyée sur la construction d'une nouvelle mesure de similarité extraite à partir d'attributs de texture. Ces attributs sont déterminés à partir de moments discrets. La démarche adoptée a respecté l'approche classique de la détection des changements dans les images à THRS à savoir une phase de segmentation suivie d'une phase de classification. Ainsi, nous avons pu constater que deux problèmes majeurs devraient être résolus lors de l'étude de la détection des changements dans les images à THRS. Tout d'abord, l'hétérogénéité des informations disponibles. En effet, l'avènement des imageurs à THRS favorise le développement de la détection des changements de faible amplitude adaptée aux cas d'images de même nature tout comme celles de diverses natures. Le second problème est que l'augmentation de la résolution spatiale s'accompagne d'une diminution de la résolution spectrale ce qui entraîne la prise en compte simultanée de l'information spectrale et de l'aspect textural.

Une revue de la littérature a montré que les méthodes étaient adaptées à la nature des applications et que les méthodes adaptées à l'hétérogénéité des senseurs s'appuyaient normalement sur des mesures de similarité statistique telle que le coefficient de corrélation linéaire, l'information mutuelle ou la divergence de Kullback-Liebler qui malheureusement, se montrent moins performantes dans l'étude des détections des changements pour les capteurs hétérogènes. Afin de prendre en compte l'information texturale, nous avons extraits des attributs de textures à partir des moments locaux orthogonaux discrets de Tchebychev. Ces descripteurs notamment utilisées en reconnaissance de forme pour leur bonne performance et leur stabilité numérique et algorithmique ont été étendus à une famille particulière des moments à savoir les moments orthogonaux discrets de Tchebychev TRE invariants. Ces moments invariants par translation, rotation et facteur d'échelle permettent de discriminer toutes les classes de texture de façon unique quel que soit les changements d'orientation de la classe de texture. L'extraction automatique des objets s'est faite à l'aide de la méthode de superpixels qui ont permis de regrouper les pixels sous forme de région atomique en fonction de leur intensité spectrale. Les descripteurs obtenus de cette segmentation nous ont permis d'avoir une nouvelle mesure de similarité par une modélisation de la dépendance entre les paramètres des

distributions marginales des images des descripteurs. Afin de tenir compte de la dépendance spatiale, une régularisation par chaîne de Markov couplée avec copule est utilisée. L'estimation de la densité de copule s'est effectuée à l'aide des polynômes orthogonaux de Legendre restreints à l'intervalle unité. Les premiers résultats encourageants ont été obtenus sur des images de synthèse et des images réelles présentant les différents cas les plus couramment rencontrés dans la pratique. Les taux de détection des zones changées sont meilleurs que ceux obtenus par les mesures de similarité telles que le coefficient de corrélation linéaire et l'information mutuelle quelle que soit la nature des senseurs utilisés.

Perspectives

Au cours des diverses expériences menées lors de la construction de la nouvelle mesure de similarité, certaines limites ont été constatées et constituent des axes de recherches qui pourraient améliorer les résultats. Le premier axe de recherche est la définition de paramètres optimaux concernant le nombre de superpixels qui est fixé manuellement dans la phase de segmentation afin d'obtenir un nombre suffisant d'échantillons pour l'estimation de la mesure. Une alternative intéressante serait d'utiliser les cartes auto-organisatrices de Kohonen. Nous avons par ailleurs mené des études préliminaires à ce sujet qu'il serait opportun de poursuivre. Un autre axe de recherche intéressant est l'utilisation d'un classifieur améliorant les résultats des chaînes de Markov couplées. En effet ce classifieur impose la stationnarité du processus couplé et dans un contexte plus général d'images présentant de fortes non-stationnarités statistiques l'extension aux modèles triplets s'avère une alternative intéressante.

Liste des publications de l'auteur

Les différentes contributions issues des travaux de cette thèse ont donné lieu à 3 articles parmi lesquels, un article publié dans un journal indexé THOMSON Reuters et le second dans un journal à comité de lecture. Le troisième article est en cours de publication dans un journal indexé THOMSON Reuters. Cet article est en cours de revision.

Articles de revues parus

- Armand Kodjo Atiampo, and Georges Laussane Loum. “Unsupervised Image Segmentation with Pairwise Markov Chains Based on Nonparametric Estimation of Copula Using Orthogonal Polynomials.” *Int. J. Image Graphics* 16 (2016): 1-15.

<http://www.worldscientific.com/doi/pdf/10.1142/S0219467816500200>

- Georges Laussane Loum, Atiampo Kodjo Armand, Pandry Koffi Ghislain and Souleymane Oumtanaga, « Application of Morphological Component Analysis to Optical Image Fusion » *American Journal of Applied Sciences* 14(8) (2017) :795-807

<http://thescipub.com/PDF/ajassp.2017.795.807.pdf>

Articles soumis dans les revues à paraître

- Georges Laussane Loum, Pandry Koffi Ghislain, Atiampo Kodjo Armand, « A hybrid model of diffusion based on the Jeffreys Type Equation for noise reduction on images » soumis au journal IET Image Processing.

ANNEXES

ANNEXE A : Estimation des moments de Tchebychev TRE invariants

Les moments de Tchebychev TRE invariants sont définis par :

$$I_{n,m}^{(trs)} = \omega^2 \sum_{k=0}^{n+m} \sum_{j=0}^{n+m-k} \lambda_{n,m,k,j}^{(trs)} T_{k,j}$$

$$n, m \in \{0, 1, \dots, \min\{N_0 - 1, N_s - 1\}\}$$

avec

$$\lambda_{n,m,k,j}^{(trs)} = \lambda_{n,m,k,j} \begin{pmatrix} \omega \cos \theta, & \omega \sin \theta, \\ -\omega \bar{x} \cos \theta - \omega \bar{y} \sin \theta + \frac{N_s - 1}{2}; \\ -\omega \sin \theta, & \omega \cos \theta. \end{pmatrix} \Big|_{N_0, N_s}$$

Le coefficient d'échelle ω est défini par :

La relation de récurrence des moments TRE invariants est donnée par :

et

$$\begin{aligned}
\lambda_{n,m,k,j}^{(trs)} &= \lambda_{n,m-1,k+1,j}^{(trs)} \omega \sin \theta K_{m,k+2}^{N_s, N_0} \tilde{C}_{k+2}^{N_0} - \lambda_{n,m-1,k,j+1}^{(trs)} \omega \cos \theta K_{m,j+2}^{N_s, N_0} \tilde{C}_{j+2}^{N_0} \\
&+ \lambda_{n,m-1,k,j}^{(trs)} \omega \tilde{A}_m^{N_s} \left[-\sin \theta \left(\frac{N_0-1}{2} - \bar{x} \right) + \cos \theta \left(\frac{N_0-1}{2} - \bar{y} \right) \right] \\
&- \lambda_{n,m-1,k-1,j}^{(trs)} \omega \sin \theta K_{m,k}^{N_s, N_0} + \lambda_{n,m-1,k,j-1}^{(trs)} \omega \cos \theta K_{m,j}^{N_s, N_0} \\
&+ \lambda_{n,m-2,k,j}^{(trs)} \tilde{C}_m^{N_s}.
\end{aligned}$$

Le paramètre est estimé de façon récurrente.

Pour $m=0, n=0$, nous avons

$$\lambda_{0,0,0,0}^{(trs)} = \left(\frac{N_0}{N_s} \right)$$

Pour $n=1, m=0$

$$\begin{aligned}
\lambda_{1,0,1,0}^{(trs)} &= \omega \cos \theta K_{1,1}^{N_s, N_0} \left(\frac{N_0}{N_s} \right) \\
\lambda_{1,0,0,1}^{(trs)} &= \omega \sin \theta K_{1,1}^{N_s, N_0} \left(\frac{N_0}{N_s} \right) \\
\lambda_{1,0,0,0}^{(trs)} &= \omega \tilde{A}_1^{N_s} \left(\frac{N_0}{N_s} \right) \left\{ \cos \theta \left(\frac{N_0-1}{2} - \bar{x} \right) + \sin \theta \left(\frac{N_0-1}{2} - \bar{y} \right) \right\}.
\end{aligned}$$

Pour $n=0, m=1$

$$\begin{aligned}
\lambda_{0,1,1,0}^{(trs)} &= -\omega \sin \theta K_{1,1}^{N_s, N_0} \left(\frac{N_0}{N_s} \right) \\
\lambda_{0,1,0,1}^{(trs)} &= \omega \cos \theta K_{1,1}^{N_s, N_0} \left(\frac{N_0}{N_s} \right) \\
\lambda_{0,1,0,0}^{(trs)} &= \omega \tilde{A}_1^{N_s} \left(\frac{N_0}{N_s} \right) \left\{ -\sin \theta \left(\frac{N_0-1}{2} - \bar{x} \right) + \cos \theta \left(\frac{N_0-1}{2} - \bar{y} \right) \right\}
\end{aligned}$$

Pour $n=1, m=1$

$$\begin{aligned}
\lambda_{1,1,2,0}^{(\text{trs})} &= -\frac{\omega^2}{2} \sin(2\theta) K_{1,1}^{N_s, N_0} K_{1,2}^{N_s, N_0} \left(\frac{N_0}{N_s} \right) \\
\lambda_{1,1,0,2}^{(\text{trs})} &= \frac{\omega^2}{2} \sin(2\theta) K_{1,1}^{N_s, N_0} K_{1,2}^{N_s, N_0} \left(\frac{N_0}{N_s} \right) \\
\lambda_{1,1,1,1}^{(\text{trs})} &= \omega^2 \cos(2\theta) \left(K_{1,1}^{N_s, N_0} \right)^2 \left(\frac{N_0}{N_s} \right) \\
\lambda_{1,1,1,0}^{(\text{trs})} &= \omega^2 \tilde{A}_1^{N_s} K_{1,1}^{N_s, N_0} \left(\frac{N_0}{N_s} \right) \left\{ -\sin(2\theta) \left(\frac{N_0-1}{2} - \bar{x} \right) \right. \\
&\quad \left. + \cos(2\theta) \left(\frac{N_0-1}{2} - \bar{y} \right) \right\}
\end{aligned}$$

$$\begin{aligned}
\lambda_{1,1,0,1}^{(\text{trs})} &= \omega^2 \tilde{A}_1^{N_s} K_{1,1}^{N_s, N_0} \left(\frac{N_0}{N_s} \right) \left\{ \cos(2\theta) \left(\frac{N_0-1}{2} - \bar{x} \right) \right. \\
&\quad \left. + \sin(2\theta) \left(\frac{N_0-1}{2} - \bar{y} \right) \right\} \\
\lambda_{1,1,0,0}^{(\text{trs})} &= \omega^2 \left(\tilde{A}_1^{N_s} \right)^2 \left(\frac{N_0}{N_s} \right) \left\{ \cos(2\theta) \left(\frac{N_0-1}{2} - \bar{x} \right) \left(\frac{N_0-1}{2} - \bar{y} \right) \right. \\
&\quad \left. + \frac{1}{2} \sin(2\theta) \left[-\left(\frac{N_0-1}{2} - \bar{x} \right)^2 + \left(\frac{N_0-1}{2} - \bar{y} \right)^2 \right] \right\}
\end{aligned}$$

$$\begin{aligned}
I_{1,1}^{(\text{trs})} &= \sum_{k=0}^2 \sum_{j=0}^{2-k} \lambda_{1,1,k,j}^{(\text{trs})} T_{k,j} \\
&= \left\{ \frac{1}{2} \sin(2\theta) \left[-\left(\frac{N_0-1}{2} - \bar{x} \right)^2 + \left(\frac{N_0-1}{2} - \bar{y} \right)^2 \right] \right. \\
&\quad \left. + \cos(2\theta) \left(\frac{N_0-1}{2} - \bar{x} \right) \left(\frac{N_0-1}{2} - \bar{y} \right) \right\} \times \omega^2 \left(\tilde{A}_1^{N_s} \right)^2 \left(\frac{N_0}{N_s} \right) T_{0,0} \\
&\quad + K_{1,1}^{N_s, N_0} \omega^2 \tilde{A}_1^{N_s} \left(\frac{N_0}{N_s} \right) \left\{ \begin{array}{l} -\sin(2\theta) \left(\frac{N_0-1}{2} - \bar{x} \right) \\ +\cos(2\theta) \left(\frac{N_0-1}{2} - \bar{y} \right) \end{array} \right\} T_{1,0} \\
&\quad + K_{1,1}^{N_s, N_0} \omega^2 \tilde{A}_1^{N_s} \left(\frac{N_0}{N_s} \right) \left\{ \begin{array}{l} \sin(2\theta) \left(\frac{N_0-1}{2} - \bar{y} \right) \\ +\cos(2\theta) \left(\frac{N_0-1}{2} - \bar{x} \right) \end{array} \right\} T_{0,1} \\
&\quad + \cos(2\theta) \left(\frac{N_0}{N_s} \right) \left(K_{1,1}^{N_s, N_0} \right)^2 \omega^2 T_{1,1} \\
&\quad - \frac{1}{2} \sin(2\theta) K_{1,1}^{N_s, N_0} K_{1,2}^{N_s, N_0} \omega^2 \left(\frac{N_0}{N_s} \right) T_{2,0} \\
&\quad + \frac{1}{2} \sin(2\theta) K_{1,1}^{N_s, N_0} K_{1,2}^{N_s, N_0} \omega^2 \left(\frac{N_0}{N_s} \right) T_{0,2}.
\end{aligned}$$

ANNEXE B : Rappel sur les copules bivariées

Dans toute la suite I désigne l'intervalle $[0; 1]$

Définition B.1.1

On appelle copule bivariée toute fonction C définie de $I^2 \rightarrow I$ qui possède les propriétés suivantes :

$$(i) \quad \forall u \in I \quad C(u, 0) = C(0, u) = 0 \quad (B.1)$$

$$(ii) \quad \forall u \in I \quad C(u, 1) = C(1, u) = 1 \quad (B.2)$$

(iii) C est 2 – croissante c'est à dire: $\forall (u_1, u_2)$ et $(v_1, v_2) \in I \times I$ avec $u_1 \leq v_1$ et $u_2 \leq v_2$

$$C(v_1, v_2) - C(v_1, u_2) - C(u_1, v_2) + C(u_1, u_2) \geq 0 \quad (B.3)$$

Nous allons définir le fameux théorème de Sklar qui est à l'origine du développement de la théorie des copules. Il a été établi en 1959. Ce théorème permet de représenter toute fonction de répartition bidimensionnelle sous forme d'une copule

Théorème de Sklar (1959)

Théorème B.1.1

Soit H la fonction de répartition de deux variables aléatoires X, Y et $F(x), G(y)$ les fonction de répartition marginales. Alors il existe une copule C telle que : pour tout $x, y \in \bar{\mathbb{R}} \times \bar{\mathbb{R}}$

$$H(x, y) = C(F(x), G(y)) \quad (B.4)$$

Si F et G sont continues alors C est unique

Inversement, si C est une copule et F, G des fonctions de répartition, alors la fonction C définie dans (B.4) est une fonction de répartition jointe dont les marginales sont F et G .

Les copules admettent des densités de probabilité. Si la densité c associée à la copule C existe, alors elle est définie par :

$$c(u, v) = \frac{\partial^2 C(u, v)}{\partial u \partial v} \quad (B.5)$$

Si la fonction de répartition conjointe H est absolument continue, en utilisant le théorème de Sklar, nous pouvons exprimer la densité h d'un vecteur aléatoire (X, Y) en fonction de la densité de sa copule c et de ses fonctions de répartition marginales F et G par :

$$h(x, y) = f(x)g(y)c(F(x), G(y)) \quad (B.6)$$

Définition B.1.2

Une copule C bivariée définie sur $[0; 1]^2$ est une fonction de répartition jointe sur X, Y et dont les marginales F et G sont uniformes sur $[0; 1]$

Corollaire B.1.1

Soit H une fonction de répartition bidimensionnelle de fonctions de répartition marginales F et G . Alors la copule C associée à H est donnée par :

$$C(u, v) = H(F^{-1}(u)G^{-1}(v)) \quad (B.7)$$

Enfin, on peut mentionner que si φ est une fonction strictement croissante et dérivable et C une copule alors $C_\varphi(u, v) = \varphi^{-1}(C(\varphi(u), \varphi(v)))$ définit une copule.

B.2. Copules archimédiennes

La famille des copules archimédiennes, regroupe un certain nombre de copules notamment les copules de Clayton, de Gumbel, et de Frank. Ces copules sont construites à l'aide d'une fonction φ appelée générateur qui est une fonction de classe C^2 telle que $\varphi(1) = 0$, $\varphi'(u) \leq 0$ et $\varphi''(u) > 0$.

Une copule archimédienne de générateur φ est donc définie par :

$$C(u_1, u_2) = \varphi^{-1}(\varphi(u_1) + \varphi(u_2)) \quad (B.8)$$

Une propriété intéressante des copules archimédiennes est leur symétrie :

$$C(u_1, u_2) = C(u_2, u_1) \quad (B.9)$$

B.3. Copules elliptiques

Cette famille de copules comprend la copule gaussienne et la copule de Student. Le générateur de cette famille de copules appartient à la famille des lois elliptiques. Une loi continue est dite elliptique de paramètre de position $\mu = (\mu_1, \mu_2) \in \mathbb{R}^2$ et de matrice de forme symétrique définie positive $\Sigma \in \mathcal{M}_2(\mathbb{R})$ si sa densité f peut s'écrire pour tout $x = (x_1, x_2) \in \mathbb{R}^2$

$$f(x) = \det(\Sigma)^{\frac{1}{2}} g((x - \mu)\Sigma^{-1}(x - \mu)^T) \quad (B.10)$$

La fonction g est une fonction à valeurs positives vérifiant $\int g(\langle x, x^T \rangle) dx = 1$ (B11)

Tout comme les copules archimédiennes, ces copules sont symétriques.

Bibliographie

- R. Achanta, A. Shaji, K. Smith, A. Lucchi, P. Fua, and S. Susstrunk, «*SLIC Superpixels.*» Édité par EPFL. Technical Report, n° 149300 (June 2010).
- R. Achanta, A. Shaji, K. Smith, A. Lucchi, P. Fua, et S. Susstrunk. «SLIC Superpixels compared to state of art of superpixels methods.» *journal of latex class files*, 6 n° 1 (Décembre 2011).
- O. A. Ajadi, F. J. Meyer and P. W. Webley, «Change Detection in Synthetic Aperture Radar Images Using a Multiscale-Driven Approach.» *Remote Sens.* 8 n° 482 (2016).
- S. Aksoy, G. Akçay, T. Wassenaar. «Automatic mapping of linear woody vegetation features in agricultural landscapes.» *IEEE Transactions on Geoscience and Remote Sensing* 48 n° 1 (2010): 511-522.
- V. Alberga. «Similarity Measures of Remotely Sensed Multi-Sensor Images for Change Detection Applications.» *Remote Sensing* 1 n° 3 (2009): 122–143.
- F. Argenti, A. Lapini, T. Bianchi, L. Alparone. «A Tutorial on Speckle Reduction in Synthetic Aperture Radar Images.» *IEEE Geoscience And Remote Sensing Magazine*, 1 n° 3 (2013): 6-35.
- S. Arivazhagan, L. Ganesan, T. S. Kumar, «Texture classification using curvelet statistical and co-occurrence features.» Proceedings of the IEEE International Conference on Pattern Recognition. 2006, 938-941.
- J. Arndt. *Matters Computational Ideas, Algorithms, Source Code.* Springer, 2011.
- L. E. Baum, T. Petrie, G. Soules, N. Weiss, «A maximization technique occurring in the statistical analysis of probabilistic functions of Markov chain.» *Ann. of Math. Statistics* 41 (1970): 164–171.
- J. Baumgartner, A. G. Flesia, J. Gimenez, J. Pucheta. «A new image segmentation framework based on two-dimensional hidden Markov models.» *Integrated Computer-Aided Engineering* (2014): 1–13.
- Y. Bazi, L. Bruzzone, and F. Melgani. «An Unsupervised Approach Based on the Generalized Gaussian Model to Automatic Change Detection in Multitemporal SAR Images.» *IEEE Trans. Geosci. Remote Sens.* 43 n° 4 (2005): 874–887.
- Y. Bazi, L. Bruzzone, F. Melgani. «Image thresholding based on the EM algorithm and the generalized gaussian distribution.» *Pattern Recognit.*, n° 40 (2007): 619–634.
- C. Benedek, M. Shadaydeh, Z. Kato, T. Sziranyi, J. Zerubia. «Multilayer Markov Random Field Models for Change Detection.» *ISPRS J. Photogrammetry and Remote Sensing*, n° 107. (2015): 22–37.
- C. Benedek, T. Sziranyi. «Change detection in optical aerial images by a multilayer conditional mixed Markov model.» *IEEE Trans. Geosci. Remote Sens.* 47 n° 10 (2009): 3416–3430.

- B. Benmiloud, W. Pieczynski. «Estimation des paramètres dans les chaînes de Markov cachées.» *Traitement du Signal* 12, n° 5 (1995): 433 - 453.
- M. Ben Mabrouk. «*Modèle de Markov Triplet en restauration des signaux.*» Thèse de Doctorat conjoint Télécom & Management Sud Paris et Université Pierre et Marie Curie (2012).
- T. Blaschke. «Object based image analysis for remote sensing.» *ISPRS Journal of Photogrammetry & Remote Sensing* 65 n° 1 (2010): 2–16.
- T. Blaschke. *Multifunctional Landscapes Vol III : Continuity and Change*, chapitre : Continuity, complexity and change: A hierarchical geoinformation-based approach to exploring patterns of change in a cultural landscape. Southampton, Boston: WIT press, 2003.
- M. Y. Boudaren, E. Monfrini, and W. Pieczynski. «Unsupervised segmentation of random discrete data hidden with switching noise distributions.» *IEEE Signal Processing Letters* 19 n° 10 (October 2012): 619-622.
- T. Bouezmarni, A. El Ghouch, A. Taamouti. «Bernstein Estimator for Unbounded Copula Densities.» *Statistics & Risk Modeling*, 30 (2013): 343–360.
- T. Bouezmarni, J. Rombouts, A. Taamouti. «Asymptotic properties of the Bernstein density copula estimator for α -mixing data.» *Journal of Multivariate Analysis*, 101 (2010): 1–10.
- N. Bouhlel, G. Ginolhac, E. Jolibois, A. Atto. «Multivariate statistical modeling for multi-temporal SAR change detection using wavelet transforms.» Édité par Proceedings of MultiTemp. 8th International Workshop on the Analysis of Multitemporal Remote Sensing Images. Annecy, France., 2015, 1-4.
- F. Bovolo and L. Bruzzone. «“An adaptive technique based on similarity measures for change detection in very high resolution sar images,”» *Geoscience and Remote Sensing Symposium, IGARSS IEEE International*, 2008. 158 - 161.
- F. Bovolo and L. Bruzzone. «A Theoretical Framework for Unsupervised Change Detection Based on Change Vector Analysis in the Polar Domain”» *IEEE Trans. Geosci. Remote Sens.* 45 n° 1 (2007): 218–236.
- F. Bovolo, L. Bruzzone. « A detail-preserving scale-driven approach to change detection in multitemporal SAR images.» *IEEE Trans. Geosci. Remote Sens.* 43 (2005): 2963–2972.
- R. Brunet, R. Ferras et H. Théry. *Les mots de la géographie*. La Documentation Française. rellus edition, 2009.
- D. Brunner, G. Lemoine, and L. Bruzzone, «Change detection for earthquake damage assessment in built-up areas using very high resolution optical and SAR imagery.» *Geoscience and Remote Sensing, Symposium (IGARSS). IEEE International*, 2010. 3210-3213.
- D. Brunner, G. Lemoine, and L. Bruzzone. « Earthquake damage assessment of buildings using VHR optical and SAR imagery,”» *IEEE Transactions on Geoscience and Remote Sensing* 48 n° 5 (2010): 2403-2420.

- L. Bruzzone, D.F. Prieto. «Automatic analysis of the difference image for unsupervised change detection.» *IEEE Transactions on Geoscience and Remote Sensing* 38 (2000): 1171–1182.
- L. Bruzzone, D.F. Prieto. «Automatic analysis of the difference image for unsupervised change detection.» *IEEE Trans. Geosci. Remote Sens.* 38 (2000): 1171–1182.
- L. Bruzzone, F. Bovolo. «A Novel Framework For The Design Of Change-Detection Systems For Very High Resolution Remote Sensing Images.» *Proceedings of IEEE* 101 n° 3 (2012): 609 - 630.
- F. W. Campbell, J. G. Robson. «Application of Fourier analysis to the visibility of gratings.» *Journal of Physiology* 197 (1968): 551-566.
- C. Carincotte, S. Derrode, et S. Bourennane. «Unsupervised change detection on SAR images using fuzzy hidden Markov chains.» *IEEE Trans. Geosci. Remote Sens.* 44, n° 2 (2006): 432–441.
- G. Celeux, D. Chauveau et J. Diebolt. «Stochastic versions of the EM algorithm : an experimental study in the mixture.» *Journal of Statistical Computation and Simulation*, 55 n° 4 (1996): 287-314.
- T. Celik and K.-K. Ma. «Unsupervised Change Detection for Satellite Images Using Dual-Tree Complex Wavelet Transform.» *IEEE Trans. Geosci. Remote Sens.* 48 n° 3 (2010): 1199–1210.
- T. Celik, K.-K. Ma. « Multitemporal image change detection using undecimated discrete wavelet transform and active contours.» *IEEE Trans. Geosci. Remote Sens.* , n° 49 (2011): 706–716.
- T. Celik. «A bayesian approach to unsupervised multiscale change detection in synthetic aperture radar images.» *Signal Process.*, n° 90 (2010,): 1471–1485.
- T. Celik. «Multiscale change detection in multitemporal satellite images.» *IEEE Trans. Geosci. Remote Sens.*, n° 6 (2009,): 820–824. .
- T. Celik. «Unsupervised change detection in satellite images using principal component analysis and-means clustering.» *IEEE Geosci. Remote Sens. Lett.*, n° 6 (2009): 772–776.
- M. Chabert and J.-Y. Tournet. «Bivariate Pearson distributions for remote sensing images.» *Proc. IEEE Int. Geosci. Remote Sens. Symp. (IGARSS)*. Vancouver, Canada, 2011. 4038–4041.
- F. Chatelain, J.-Y. Tournet, J. Inglada, «Bivariate Gamma Distributions for Image Registration and Change Detection. » *IEEE Trans. Image Process.* 16, n° 7 (2007): 1796–1806.
- G. Chen, G. J. Hay, L. M. T. Carvalho and M. A. Wulder, «Object-based change detection. » *International Journal of Remote Sensing* 33, n° 14 (2012): 4434-4457.
- S. X. Chen, «Probability Density Function Estimation using Gamma Kernels.» *Ann. Inst. Statist. Maths* 52 (2000): 471–480.

- S. X. Chen, and T. M. Huang, «Nonparametric estimation of copula functions for dependence modelling.» *La Revue Canadienne de statistique* 35 (2007): 265-282.
- E. Colin-Koeniguer, F. Janez, «Détection de changement sur des images sar de résolutions et de mode polarimétrique différents.» *XXVIème Colloque GRETSI*. BREST, France., 2013.
- P. R. Coppin, and M. E. Bauer, «Processing of multitemporal landsat TM imagery to optimize extraction of forest cover change features.» *IEEE Trans. on Geoscience and Remote Sensing* 32 n° 4 (1994): 918–927.
- D. Crispell, J. Mundy, et G. Taubin,. «A variable-resolution probabilistic three-dimensional model for change detection.» *IEEE Trans. Geosci. Remote Sens.* 50, n° 2. (2012): 489–500.
- P. J. Curran. «The semivariogram in remote sensing: an introduction.» *Remote Sensing of Environment*, 24 (1988): 493-507.
- D. P. A. Dassanayake, I. Volobouev, and A. Trindade, « Local Orthogonal Polynomial Expansion for Density Estimation.» *Stats. AP.* 3 (2015): 1-24.
- X. Day, and S. Khorram, «The effects of image misregistration on the accuracy of remotely sensed change detection.» *IEEE Trans. on Geoscience and Remote Sensing*, n° 36 (1998): 1566–1577.
- R. L. De Valois, D. G. Albrecht, L. G. Thorell, «Spatial frequency selectivity of cells in macaque visual cortex.» *Vision Research* 22 (1982): 545-559.
- A. J. W. De Wit and J. G. P. W. Clevers. « Efficiency and accuracy of per-field classification for operational crop mapping.» *International Journal of Remote Sensing*, 25 (2004): 4091–4112.
- A. P. Dempster, N. M. Laird and D. B. Rubin, « Maximum likelihood from incomplete data via the EM algorithm.» *Journal of the Royal Statistical Society. Series B (Methodological)* 39 n° 1 (1977): 1-38.
- S. Derrode and W. Pieczynski. «Unsupervised data classification using pairwise Markov chains with automatic copulas selection.» *Computational Statistics and Data Analysis*, 63 (July 2013): 81-98.
- S. Derrode, W. Pieczynski, « Unsupervised classification using hidden Markov chain with unknown noise copulas and margins.» *Signal Processing, Elsevier* 128 n° 11 (2016): 8-17.
- S. Derrode, W. Pieczynski,. «Signal and Image Segmentation using Pairwise Markov Chain.» *IEEE Trans. Signal Process.* 59, n° 2 (2004): 2477-2489.
- P. Devijver. «Baum’s Forward-Backward algorithm revisited.» *Pattern Recognition Letters* 39 n° 3 (1985): 369–373.
- M. N. Do, M. Vetterli, « The finite ridgelet transform for image representation.» *IEEE Transactions on Image Processing* 12 n° 1 (2003): 16-28.

- L. Dragut, D. Tiede, S. R. Levick, «ESP : a tool to estimate scale parameter for multiresolution image segmentation of remotely sensed data.» *International Journal of Geographical Information Science* . , n° 24 (2010): 859-871.
- C. E. Woodcock, S. A. Macomber, M. Pax-Lenney, W.B. Cohen. «Monitoring large areas for forest change using Landsat: generalization across space, time and Landsat sensors.» *Remote Sensing of Environment*, n° 78 (2001): 194–203.
- S. Efromovich. «Orthogonal series density estimation.» *WIREs Comp. Stat.* 2 (2010): 467-476.
- J. F. Feddema, K. W. oleson, G. B. Bonan, L. O. Mearns, L. E. Buja, G. A. Meehl, W. M. Washington, « The importance of Land Cover Change in Simulating Future Changes.» *Science* 310 n° 5754 (2005): 1674-1678.
- M. A. T. Figueiredo and A. K. Jain. «Unsupervised learning of finite mixture models.» *IEEE Trans. Pattern Anal. Mach. Intell.* 24 n° 3 (Mar. 2002): 381–396.
- P. Fisher, C. Arnot, R. Wadsworth, J. Wellens, «Detecting change in vague interpretations of landscapes.» *Ecological Informatics*, n° 1 (2006): 163–178.
- P. Fisher. «The pixel: a snare and a delusion.» *International Journal of Remote Sensing* 18 (1997.): 679–685.
- D. Flora, J. Delon, Y. Gousseau, J. Michel, and F. Tupin, «Change detection for high resolution satellite images, based on sift descriptors and an a contrario approach.» *IGARSS*, Jul 2014. Québec, Canada, 2014.
- J. A. Foley, R. Defries, G. P. Asner, C. Bradford, G. Bonan, S. R. Carpentier, S. F. Chapin, M. T. Coe, G. C. Daily, H. K. Gibbs, J. H. Helkowski, T. Holloway, E. A. Howard, C. J. Kucharik, C. Monfreda, J. A. Patz, C. L. Prentice, N. Ramankutry, «Global Consequence of Land Use . . .» *Science* 309, n° 5734 ((2005)): 540-574.
- B. G. Koffi, G. Ouattara, F. K. Kouame, et J.-P. Deroin, «Analyse des images satellitaires radar RSO-ERS et optique ETM+ de Landsat 7 comme outils de prospection minière : application aux localités de Tiébissou et de Tienko en Côte d'Ivoire (Afrique de l'Ouest.» *Afrique Science* 10, n° 1 (2014): 47 - 67.
- V. V. Garg, L. Tenorio, K. Willcox. «Minimum Local Distance Density Estimation.» *stats.ME* 46 (2014): 1-21.
- S. Geman, D. Geman, «Stochastic relaxation, Gibbs distributions and the Bayesian restoration of images.» *IEEE Trans. on Pattern Analysis and Machine Intelligence* 6 n° 6 (1984): 721–741.
- A. Ghosh, B. N. Subudhi, and L. Bruzzone, «Integration of Gibbs Markov Random Field and Hopfield-Type Neural Networks for Unsupervised Change Detection in Remotely Sensed Multitemporal Images.» *IEEE Trans. Image Process.* 22 n° 8 (2013): 3087–3096.
- R. M. Haralick, «Statistical and structural approaches to texture.» *Proceedings of the IEEE*, 67 n° 5 (1979): 786-804.

- R. M. Haralick, K. Shanmugam, I. Dinstein, «Textural features for image classification. » *IEEE Transactions on Systems, Man and Cybernetics, SMC* 3 n° 6 (1973): 610-621.
- N.-B. Heidenreich, A. Schindler, S. Sperlich, « Bandwidth selection for kernel density estimation: a review of fully automatic selectors. » *Advances in Statistical Analysis* 97 (2013): 403-433.
- A. Hernando, D. Tiede, F. Albrecht, S. Lang, «Spatial and thematic assessment of object-based forest stand delineation using an OFA matrix.» *International Journal of Applied Earth Observation and Geoinformation*, n° 19 (2012): 214-225.
- T. Hoberg, F. Rottensteiner, R. Feitosa, C. Heipke, «Conditional random fields for multitemporal and multiscale classification of optical satellite imagery.» *IEEE Trans. Geosci. Remote Sens.* 53 n° 2 (2015): 659–673.
- M.-K. Hu. «Visual pattern recognition by moment invariants.» *Information Theory, IRE Transactions* 8 (1962): 179-187.
- C. Huang, K. Song, S. Kim, J.R.G. Townshend, P. Davis, J.G Masek, S.N. Goward,. «Use of a dark object concept and support vector machines to automate forest cover change analysis.» *Remote Sensing of Environment* 112 (2008.): 970–985.
- D. Huard, G. Évin, A. Favre, «Bayesian copula selection. » *Computational Statistics & Data Analysis* 51 (2006): 809–822.
- L. Hubert-Moy. «Occupation du sol et Télédétection : De l'inventaire à la modélisation prédictive.» Mémoire d'habilitation à diriger des recherches, COSTEL UMR, CNRS 6554 LETG, 10 2004.
- M. Hussain et al. «Change detection from remotely sensed images: From pixel-based to object-based approaches.» *ISPRS J. Photogramm. Remote Sens.* 80 (2013): 91–106.
- J. Inglada and A. Giros. «On the possibility of automatic multisensor image registration.» *IEEE Trans. Geosci. Remote Sens.* 42, n° 10 (Oct. 2004): 2104–2120.
- J. Inglada and G. Mercier. «A New Statistical Similarity Measure for Change Detection in Multitemporal SAR Images and Its Extension to Multiscale Change Analysis.» *IEEE Trans. Geosci. Remote Sens.* 45 n° 5 (May 2009): 1432–1445.
- J. Inglada. *État de l'art en détection de changements sur les images de télédétection*. Toulouse: Rapport technique, CNES, 2001.
- K. Johansen, L.A. Arroyo, S. Phinn, C. Witte, «Comparison of geo-object based change detection of riparian environments using high spatial resolution multi-spectral imagery.» *Photogrammetric Engineering & Remote Sensing*, n° 76 (2010): 123–136.
- B. Julesz, «Textons, the elements of texture perception, and there interactions.» *Nature* 290 n° 5802 (1981): 91-97.
- B. Julesz. «Visual pattern discrimination.» *IRE Transactions on Information Theory* 8 (1962): 84-92.
- T. Kasetkasem, P.K. Varshney, « An image change detection algorithm based on markov random field models.» *IEEE Trans. Geosci. Remote Sens.* 40 (2002): 1815–1823.

- G. Kauermann, C. Schellhase, D. Ruppert, «Flexible copula density estimation with penalized hierarchical b-splines.» *Scand. J. Stat.* 40, n° 4 (2013): 685–705.
- R. E. Kennedy, P.A. Townsend, J.E. Gross, W.B. Cohen, P. Bolstad, Y.Q. Wang, P. Adams, «Remote sensing change detection tools for natural resource managers: understanding concepts and tradeoffs in the design of landscape monitoring projects.» *Remote Sensing of Environment* 113 (2009): 1382–1396.
- S. Khorram, G.S. Biging, N.R. Chrisman, D.R. Colby, R.G. Congalton, J.E. Dobson, R.L. Fergusson, M.F. Goodchild, J.R. Jensen and T.H. Mace, *Accuracy assessment of remote sensing-derived change detection*. Édité par American Society for Photogrammetry and Remote Sensing. Bethesda, Maryland, 1999.
- G. Kim, J. Silvapulle, P. Silvapulle, «Comparison of semiparametric and parametric methods for estimating copulas.» *Computational Statistics & Data Analysis* 51 (2007): 2836–2850.
- V. Krylov, G. Moser, S. B. Serpico, and J. Zerubia, «Supervised high resolution dual polarization SAR image classification by finite mixtures and copulas.» *IEEE J. Sel. Top. Signal Proc.* 5, n° 3 (2011): 554–566.
- P. Kupidura, P. Koza, «Radar imagery filtering with use of the mathematical morphology operations.» *Polish Journal of Environmental Studies* 17 n° 1C (2008): 31-35.
- N. Kwak and C.-H. Choi. «Input feature selection by mutual information based on Parzen window.» *IEEE Trans. Pattern Anal. Mach. Intell.* 24 n° 12 (Dec. 2002): 1667–1671.
- R. Kwitt, A. Uhl, «A joint model of complex wavelet coefficients for texture retrieval.» *Proceedings of the 2009 IEEE International Conference on Image Processing. IEEE Proceedings*, 2009. 1877-1880.
- E. F. Lambin and H. J. Geist. *Land use and Land Cover Change : Local Processes and Global Impact*, Heidelberg: Springer, 2006.
- E.F. Lambin et al. «The causes of land-use and land-cover change : moving beyond the myths.» *Global Environmental Change* 11 n° 1 (2001): 261–269.
- N.-E. Lasmar, Y. Berthoumieu, «Gaussian copula multivariate modeling for texture image retrieval using wavelet transforms.» *IEEE Transactions on Image Processing* 23 n° 5 (2014): 2246-2261.
- Mathieu Lavoie , «Polynômes orthogonaux » ,Maitrise de mathématiques, Université de Laval, Québec, (2015)
- R. Lecerf, «Suivi des changements d'occupation et d'utilisation des sols d'origine anthropique et climatique à l'échelle régionale par télédétection moyenne résolution (Application à la Bretagne).» *Geography*, Université Rennes 2; Université Européenne de Bretagne, 2010.
- J.-S. Lee et I. Jurkevitch. «Segmentation of SAR images.» *IEEE Trans. Geoci. Remote Sens.* 27 n° 6 (1989): 674-680.

- J.-S. Lee, L. Jurkevich, P. Dewaele, P. Wambacq and A. Oosterlinck, «Speckle filtering of synthetic aperture radar images : A review.» *Remote Sensing Reviews* 8 n° 4 (1994): 313-340.
- A. Lefebvre, T. Corpetti, L. Hubert-Moy, «Discrimination de textures dans des images à Très Haute Résolution Spatiale pour l'analyse du changement.» *ORASIS'09 - Congrès des jeunes chercheurs en vision par ordinateur*. Trégastel, France, 2009.
- A. Lefebvre. «*Contribution de la texture pour l'analyse d'images à très haute résolution spatiale : application à la détection de changement en milieu périurbain.*» Thèse de Doctorat, Geography, Université Rennes 2; Université Européenne de Bretagne, Rennes, 2011.
- J. K. Lein. «Object-Based Analysis, Environmental Sensing : Analytical Techniques for Earth Observation,» (Springer) 2012:00:00 259-278.
- H.-C. Li, W. Hong, Y.-R. Wu et P.-Z. Fan, «On the empirical statistical modeling of SAR images with generalized gamma distribution.» *IEEE J. Sel. Top. Signal Process* 5 n° 3 (2011): 386-397.
- N. Li, H. Huo, T. Fang, «A novel texture-precède segmentation algorithm for high-resolution imagery.» *IEEE Transactions on Geoscience and Remote Sensing* 48 n° 7 (2010): 2818-2828.
- H. Liu, M., Shu, H., Zhang, H. and Luo, L. Zhu, «General form for obtaining discrete orthogonal moments.» *IET Image Processing* 4 n° 5 (2010): 335–352.
- L. Liu, Y. Jiang, and C. Wang, «Noise Analysis and Image Restoration for Optical Sparse Aperture Systems.» *Int. Workshop on Educ. Tech. And Training, and Geosci. and Remote Sensing*. Shanghai, China, 2008. 353–356.
- N. Longbotham et al. «Multi-Modal Change Detection, Application to the Detection of Flooded Areas: Outcome of the 2009–2010 Data Fusion Contest. .» *IEEE J. Sel. Topics Appl. Earth Obs. Remote Sens.* 5 n° 1 (2012): 331–342.
- D. Lu, P. Mausel, E. Brondizio et E.F. Moran, «Change detection techniques.» *International Journal of Remote Sensing*, 25 (2004): 2365–2407.
- Valet Ludovic. <<Généralités sur les polynômes orthogonaux. >>. DEA. Polynômes orthogonaux,(2000), pp.49
- R. D. Macleod, R.G. Congalton, «A quantitative comparison of change-detection algorithms for monitoring eelgrass from remotely sensed data.» *Photogrammetric Engineering and Remote Sensing*, 64 n° 3 (1998): 207–216.
- P. Maillard. «Comparing texture analysis methods through classification.» *Photogrammetric Engineering and Remote Sensing*, 69 n° 4 (2003): 357-368.
- P. Malec, and M. Schienle, « Nonparametric kernel density estimation near the boundary.» *Computational Statistics and Data Analysis*, 72 (2014): 57-76.

- S. Mallat. « A theory for multiresolution signal decomposition: the wavelet representation. .» *IEEE Transactions on Pattern Analysis and Machine Intelligence* 11 n° 7 (1989): 674-693.
- B. S. Manjunath, W. Y. Ma, «Texture features for browsing and retrieval of image data.» *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 18 n° 8 (1996): 837-842.
- M. Mansourpour, M.A. Rajabi, J. A. R. Blais, «Effects and Performance of Speckle Noise Reduction Filters on Active Radars and SAR Images.» (*International Archives of ISPRS*) XXXVI 1/W41 (2006.).
- J.-F. Mari, El-Ghali Lazrak, Marc Benoît, «Time space stochastic modeling of agricultural landscapes for environmental issues.» *Environmental modelling & software*, n° 46 (2013): 219 -227.
- T. R. Martha, N. Kerle, C.J. van Westen, V. Jetten, K.V. Kumar, «Segment optimization and data-driven thresholding for knowledge-based landslide detection by object-based image analysis.» *IEEE Transaction on Geoscience and Remote Sensing* 49 (2011): 4923-4943.
- D. Massonnet et J.-C. Souyris. *Imaging with synthetic aperture radar*. . Epfl Press, 2008.
- G. Mercier, G. Moser, and S. B. Serpico, «Conditional Copulas for Change Detection in Heterogeneous Remote Sensing Images.» *IEEE Trans. Geosci. Remote Sens.* 46, n° 5 (May 2008): 1428–1441.
- G. Metternicht. «Change detection assessment using fuzzy sets and remotely sensed data: an application of topographic map revision. .» *ISPRS Journal of Photogrammetry and Remote Sensing* 54 (1999): 221–233.
- G. Moser and S. B. Serpico. «Generalized minimum-error thresholding for unsupervised change detection from SAR amplitude imagery.» *IEEE Trans. Geosci. Remote Sens.* 44, n° 10 (Oct. 2006): 2972–2982.
- G. Moser, E. Angiati, and S. B. Serpico. «Multiscale unsupervised change detection on optical images by Markov random fields and wavelets.» *IEEE Geosci. Remote Sensing Letters* 8, n° 4 (July 2011): 725–729.
- R. Mukundan, S. H. Ong, P.A. Lee, « Discrete vs. Continuous Orthogonal Moments for Image Analysis.» *CISST'01 International Conference*, 2001.
- R. Mukundan. *Local Tchebychef Moments for Texture Analysis, Moments and Moment Invariants - Theory and Applications*. Édité par G.A. Papakostas. Vol. 1. Scince Gate Publishing, 2014.
- R. B. Nelsen. *An introduction to copulas*. New York: Springer Science, 2006.
- H. Nemmour, Y. Chibani, «Multiple support vector machines for land cover change detection: an application for mapping urban extensions. .» *ISPRS Journal of Photogrammetry and Remote Sensing* 61 (2006): 125–133.
- T. Ojala, M. Pietikainen, D. Harwood,. «. A comparative study of texture measures with classification based on feature distributions.» *Pattern Recognition* 29 n° 1 (1996): 51-59.

- D. Ojuma, E. Moran, W. Connell, M. Stafford Smith, G. Laumann, J. Morais et B. Young. *Global Land Project – Science Plan and Implementation Strategy*. Stockholm, IBDP-IHDP, 2005. 64 pages.
- C. Oliver and S. Quegan. *Understanding Synthetic Aperture Radar images*. SciTech Publishing, 2004.
- G. Pajares, J. J. Ruz, and J. M. de la Cruz, «Performance Analysis of Homomorphic Systems for Image Change Detection.» *IbPRIA'05 Proceedings of the Second Iberian conference in Pattern Recognition and Image Analysis*. Lecture Notes in Computer Sciences, 2005. 563-570.
- G. Pajares, J. J. Ruz, and J. M. de la Cruz, «Performance Analysis of Homomorphic Systems for Image Change Detection.» *Pattern Recognition and Image Analysis*. 3522. (2005): 563–570.
- W. Pieczynski. «Chaînes de Markov triplet. .» *Comptes Rendus de l'Académie des Sciences Mathématique* 335 n° 3 (2002): 275–278.
- W. Pieczynski. «Pairwise Markov chains.» *IEEE Trans. on Pattern Analysis and Machine Intelligence* 25 n° 5 (2003): 634–639.
- K. G. Pillai and R. R. Vatsavai. «Multi-sensor Remote Sensing Image Change Detection: An Evaluation of Similarity Measures.» *Proc. IEEE Int. Conf. - Data Mining Workshops*. Dallas, USA, 2013. 1053–1060.
- D. Y. Po, M. N. Do, «Directional multiscale modeling of images using the contourlet transform.» *IEEE Transactions on Image Processing* 15 n° 6 (2006): 1610-1620.
- J. Prendes, M. Chabert, F. Pascal, A. Giros, and J.-Y. Tourneret, «A New Multivariate Statistical Model for Change Detection in Images Acquired by Homogeneous and Heterogeneous Sensors.» *IEEE Transactions on Image Processing*. 24 n° 3 (2015): 799-812.
- J. Prendes. *New statistical modeling of multi-sensor images with application to change detection*. Paris: Université Paris-Saclay, 2015.
- C. Proisy, P. Couteron, F. Fromard, «Predicting and mapping biomass from canopy grain analysis using Fourier-based textural ordination of IKONOS images.» *Remote Sensing of Environment* 109 (2007): 379-392.
- R. Radke, S. Andra, O. Al-Kofahi, and B. Roysam, «Image change detection algorithms: a systematic survey.» *IEEE Transactions on Image Processing* 14 n° 3 (2005): 294-307.
- O. Regniers. «Méthodes d'analyse de texture pour la cartographie d'occupations du sol par télédétection très haute résolution : application à la forêt, la vigne et les parcs ostréicoles. .» Thèse de Doctorat, Traitement du signal et de l'image. Université de Bordeaux, Bordeaux, 2014.
- M. Robin. *La télédétection. Des satellites aux systèmes d'information géographiques*. Université Nathan, 1995.

- L. A. Ruiz, J. A. Recio, A. Fernandez-Sarria, T. Hermosilla, « A feature extraction software tool for agricultural object-based image analysis.» *Computers and Electronics in Agriculture*, 76 (2011): 284-296.
- S. Sagnika, S. Bilgaiyan, S. Mishra, B. S. P. Mishra. « An exploration of change detection techniques for images.» *Journal of Theoretical and Applied Information Technology* 64, n° 3 (June 2014): 820 - 836.
- A. Schmitt, B. Wessel, A. Roth. «Curvelet-based change detection on SAR images for natural disaster mapping.» *Photogramm. Fernerkund. Geoinform.*, 2010: 463–474.
- I. W. Selesnik, R. G. Baraniuk, N. C. Kingsbury. «The dual-tree complex wavelet transform.» *IEEE Signal Processing Magazine*, 22 n° 6 (2005): 123-151.
- M. O. Sghaier, R. Lepage. «Change detection using multiscale segmentation and Kullback-Leibler divergence: Application on road damage extraction.» *8th International Workshop on the Analysis of Multitemporal Remote Sensing Images, (Multi-Temp)*, 2015.
- M. Shadaydeh and T. Sziranyi. «An improved local similarity measure estimation for change detection in remote sensing images.» *Int. Conf. Aerospace Electronic Remote Sens. Technol. Yogyakarta, Indonesia, Proceedings. IEEE*, 2014. 234–238.
- Y. Sheng, Z.G. Xia, «A Comprehensive Evaluation of Filters for Radar Speckle Suppression. .» *IEEE International Geoscience and Remote Sensing Symposium Proceedings, IEEE International Geoscience and Remote Sensin*, 1996. 1559-1561.
- S. Siachalou, G. Mallinis, M. Tsakiri-Strati. « A Hidden Markov Models Approach for Crop Classification: Linking Crop Phenology to Time Series of Multi-Sensor Remote Sensing Data.» *Remote Sensing* 7 (2015): 3633-3650.
- A. Singh. «Digital change detection techniques using remotely-sensed data.» *Int. J. Remote Sensing* 10, n° 6 (1989): 989–1003.
- A. Sklar. *Fonction de répartition à n dimensions et leurs marges*. Paris: Publications de l'Institut de Statistique de l'Université de Paris 8 1959.
- Y. Stitou, N.-E. Lasmar, Y. Berthoumieu. «Copulas based multivariate gamma modeling for texture classification.» *Proceedings of the IEEE International Conference on Acoustics, Speech and Signal Processing, IEEE Pro.*, 2009. 1045-1048.
- B. St-Onge, F. Cavayas. « Automated forest structure mapping from high resolution imagery based on directional semivariogram estimates.» *Remote Sensing of Environment* 61 (1997): 82-95.
- T. Sziranyi, M. Shadaydeh. «Segmentation of Remote Sensing Images Using Similarity-Measure-Based Fusion-MRF Model.» *IEEE Geoscience And Remote sensing letters* 11 n° 9 (2014): 1544 – 1548.
- J. Tian, S. Cui, et P. Reinartz. «Building Change Detection Based on Satellite Stereo Imagery and Digital Surface Models.» *IEEE Transactions on Geoscience and remote sensing*, 52 n° 1 (2014): 406 - 417.

- M. Tuceryan, A. K. Jain, « *Texture analysis.*» The handbook of pattern recognition and computer vision, 2 (1998.): 207-248.
- J. V. Marcos, G. Cristóbal, «Texture classification using discrete Tchebychef moments.» *J. Opt. Soc. Am. A* 30 n° 8 (August 2013): 1580-1591.
- A. Voisin, V. A. Krylov, G. Moser, S. B. Serpico, J. Zerubia, «Classification of very high resolution SAR images of urban areas using copulas and texture in a hierarchical Markov random field model,» *IEEE Geoscience and Remote Sensing Letters* 10, n° 1 (2013): 96-100.
- A. Voisin, V. Krylov, G. Moser, S. B. Serpico, J. Zerubia. «Supervised Classification of Multi-sensor and Multi-resolution Remote Sensing Images with a Hierarchical Copula-based Approach.» *IEEE Transactions on Geoscience and Remote Sensing* 52, n° 6 (2014): 3346-3358.
- A. Voisin. «*Classification supervisée d'images d'observation de la Terre à haute résolution par utilisation de méthodes markoviennes.*» Thèse de doctorat, Image Processing, Université Nice Sophia Antipolis, Nice, 2012.
- B. Wang, X. Gao, D. Tao, X. Li. «A Nonlinear Adaptive Level Set for Image Segmentation *IEEE Transactions on Systems, Man, and Cybernetics, Part B (Cybernetics)*, 44, n° 3 (2014): 418 – 428.
- F. Wang, Y. Wu, Q. Zhang, P. Zhang, M. Li, Y. Lu. «Unsupervised change detection on SAR images using triplet Markov field model. » *IEEE Geosci. Remote Sens. Lett.* 10, n° 4 (July 2013): 697–701.
- P. Wang, R. Zhong, «A multiple conditional random fields ensemble model for urban area detection in remote sensing optical images.» *IEEE Trans. Geosci. Remote Sens.* 45 n° 12 (December 2007): 3978–3988.
- G. Wenhao. «*Adaptive Series Estimators For Copula Densities.*» Electronic Theses, and Dissertations. Paper 3929 2009.
- Z. Wu, Z. Hu and Q. Fan. «Superpixel-based unsupervised change detection using multi-dimensional change vector analysis and, svm-based classification.» *XXII ISPRS Congress, 25 August – 1 September 2012. Melbourne, Australia: ISPRS Annals of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, 2012.
- X. Yang, X. Gao, D. Tao, X. Li, J. Li. «An Efficient MRF Embedded Level Set Method for Image Segmentation.» *IEEE Transactions on Image Processing*, 24 n° 1 (2014): 9 – 21.
- P. C. Yang. «*Formulation of invariants for discrete orthogonal moments and image classification.*» thèse de doctorat, Institute of Mathematical Sciences, Faculty of Science University of Malaya, Kuala Lumpur, 2013.
- P. T. Yap, R. Paramesran, and S.H. Ong. «Image analysis by Krawtchouk moments.» *IEEE Transactions on Image Processing* 12 n° 11 (2003): 1367 - 1377.
- P. T. Yap, R. Paramesran, and S.H. Ong. «Image analysis using Hahn moments.» *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 29 n° 11 (2007): 2057 - 2062.

H. Zhu. «Image representation using separable two-dimensional continuous and discrete orthogonal moments,» *Pattern Recognition* 45 n° 4 (2012): 1540–1558.

