



THESE DE DOCTORAT

Présentée par

Mr BITAM Abdelmadjid

Pour l'obtention du diplôme de Doctorat en Electronique

Thème

**ANALYSE ET SEGMENTATION D'IMAGES MULTISPECTRALES :
APPLICATION AUX IMAGES MSG.**

Thèse soutenue le 20 Novembre 2013 devant le jury :

Mr ADANE	Abd-el-Hamid	Professeur à l'USTHB	Président
Mr AMEUR	Soltane	Professeur à l'UMMTO	Rapporteur
Mr DJEDDI	Mabrouk	Professeur à l'UMB Boumerdes	Examineur
Mr BOUTARFA	Abdelhalim	Professeur à l'Université de Batna	Examineur
Mr HAMMOUCHE	Kamal	Professeur à l'UMMTO	Examineur
Mr LAHDIR	Mourad	Maître de Conférences A à l'UMMTO	Examineur

REMERCIEMENTS

Cette thèse a été effectuée au sein du laboratoire d'Analyse et de Modélisation des Phénomènes Aléatoires (LAMP) de l'Université Mouloud Mammeri de Tizi-ouzou.

J'adresse mes vifs remerciements à Monsieur Soltane Ameer, Professeur à l'Université Mouloud Mammeri de Tizi-Ouzou et Vice Recteur A la Recherche Scientifique qui a bien voulu diriger ce travail et qui m'a toujours accompagné tout au long de cette thèse.

Monsieur Abd-el-Hamid Adane, Professeur à l'Université des Sciences et de la Technologie Houari Boumédiène de Bab Ezzouar a accepté de présider le jury de soutenance, qu'il trouve ici l'expression de mes sincères remerciements.

Monsieur Mabrouk Djeddi, Professeur à l'Université Mohamed Bouguerra de Boumerdes, a bien voulu consacrer du temps à examiner le présent travail en prenant part au jury. Qu'il reçoive ici mes remerciements les plus chaleureux.

Mes remerciements vont également à Monsieur Abdelhalim Boutarfa, Professeur à l'Université de Batna qui a accepté de faire partie du jury de soutenance.

Monsieur Kamal Hammouche, Professeur à l'Université Mouloud Mammeri de Tizi-Ouzou, a accepté de participer au jury de soutenance, je le remercie fortement pour cela.

Je remercie énormément Monsieur Mourad Lahdir, Maître de Conférences classe A à l'Université Mouloud Mammeri de Tizi-Ouzou pour avoir accepté d'examiner ce travail.

Que tous ceux et toutes celles qui m'ont soutenu et aidé à mener à bien ce travail, trouvent également ici l'expression de mes remerciements.

Notations

C :	nombre de classes de l'image
X :	ensemble des pixels de l'image
N :	nombre de pixels de l'image
x_j :	descripteur multidimensionnels d'un pixel j de l'image
U :	matrice de partition floue
u_{ij} :	degré d'appartenance du pixel x_j à la classe i
b :	compteur de boucles
d_{ij} :	distance euclidienne entre les pixels i et j
g :	fonction locale de poids
w_j :	ensemble des pixels voisins dans la fenêtre autour de x_j
w :	fenêtre locale centrée sur le pixel x_j .
v_i :	centre de la i ème classe.
u_{ik} :	probabilité que le $k^{\text{ème}}$ pixel de w_j appartient à la $i^{\text{ème}}$ classe
h_j :	valeur d'homogénéité du pixel central x_j calculée sur la fenêtre locale w
cp_{jk} :	vecteur de position entre les vecteurs x_j and x_k
(m, n) :	location du pixel central x_j dans le domaine spatial
(y, z) :	location du pixel voisin x_k dans le domaine spatial
T_d :	Seuil de fusion des classes
μ_d :	la moyenne de la liste de différences dans la matrice de proximité
σ_v :	l'écart type de la liste de différences dans la matrice de proximité
a :	paramètre réglable choisi par l'utilisateur
It :	compteur d'itérations
λ :	longueur d'onde du facteur cosinus,
φ :	phase en degrés de l'onde plane sinusoïdale selon l'axe des X
σ_x :	écart type de l'enveloppe Gaussienne selon l'axe X

σ_y :	écart type de l'enveloppe Gaussienne selon l'axe Y
f :	fréquence du facteur cosinus
B :	largeur de la bande passante en octave
f_k :	le vecteur de coefficients obtenu à partir de la $K^{\text{ème}}$ bande spectrale
\mathbf{f} :	vecteur de coefficients obtenus à partir de l'ensemble des bandes spectrales.
m :	moyenne
J :	homogénéité

Abréviations

LSF :	Méthode de segmentation Locale-Spectrale Floue
FGAHL :	Méthode de segmentation par Filtrage de Gabor et Analyse d'homogénéité Locale
MSG :	Météosat Seconde Génération
SEVERI :	Spinning Enhanced Visible and Infrared Imager
FCM :	Méthode de classification C-moyennes floues
SLFCM :	Spectral-Local FCM
SFCM :	Méthode de segmentation Spatiale FCM
FLICM :	Méthode de segmentation Fuzzy Local Information C-means
SA :	Segmentation Accuracy
K_{means} :	Méthode de classification K-means
VIS0.6 :	Canal visible 0.6
VIS0.8 :	Canal visible 0.8
IR 1.6:	Canal infra rouge 1.6
IRM :	Imagerie à Résonance Magnétique
ACP :	Analyse en Composantes Principales
LAMPA :	Laboratoire d'Analyse et de Modélisation des Phénomènes Aléatoires
GERB :	Geostationary Earth Radiation Budget
HRV:	Haute Resolution Visible
REM:	Rayonnement Electromagnétique

Résumé

Dans cette thèse, nous présentons deux méthodes de segmentation d'images satellitaires météorologiques de type MSG. La majorité des méthodes de segmentation développées jusqu'à présent sont destinées aux images en niveaux de gris. Des travaux récents, ont été consacrés pour généraliser celles-ci aux images multispectrales. Cependant, ces approches utilisent généralement des stratégies de segmentation qui ne prennent pas en compte les corrélations spectrales et spatiales existantes entre les pixels de l'image. Pour palier cet inconvénient, nous avons élaboré deux techniques de segmentation qui permettent de détecter les régions d'intérêt dans des images multispectrales. La première, utilise une segmentation récursive locale-spectrale floue (LSF) qui réduit dynamiquement le nombre de classes. La deuxième est basée sur la classification floue des textures multispectrales et l'analyse d'homogénéité locale (FGAHL). Appliquées à des images synthétiques texturées couleur, les deux méthodes développées (LSF et FGAHL), rapportent des cartes de segmentation compactes et cohérentes. Les taux de bonne segmentation obtenus pour les images synthétiques sont de 98,72% et 98,46% respectivement.

Concernant les images MSG, les différents nuages ainsi que les différents types de sol et de mers ont été correctement détectés et identifiés et les contours ont été correctement reproduits par les deux techniques. Notons néanmoins une légère supériorité de l'approche LSF. En effet, cette dernière reproduit plus nettement les contours et discrimine mieux les nuages.

Mots-clés: Segmentation locale-spectrale floue, segmentation récursive, analyse d'homogénéité locale, textures spectrales, classification floue des textures multispectrales, images multispectrales MSG.

SOMMAIRE

INTRODUCTION

CHAPITRE 1 : LES IMAGES MULTISPECTRALES MSG

1.1. Préambule.....	04
1.2. La télédétection spatiale.....	05
1.3. Le rayonnement électromagnétique.....	07
1.3.1. Le domaine du visible.....	07
1.3.2. L'infrarouge.....	08
1.3.3. Les hyperfréquences.....	09
1.4. Le rayonnement et l'atmosphère.....	09
1.4.1. Absorption et émission atmosphérique.....	10
1.4.2. Diffusion atmosphérique.....	11
1.5. Le rayonnement et la matière.....	12
1.5.1. Les interactions entre le rayonnement et la matière.....	12
1.5.2. Les signatures spectrales des principales surfaces naturelles.....	13
1.6. Caractéristiques des images MSG.....	15
1.7. Formation et classification des nuages.....	18
1.7.1. Formation des nuages par soulèvement orographique.....	18
1.7.2. Les nuages de convection.....	19
1.7.3. Formation des nuages par soulèvement frontal.....	19
1.7.4. Formation des nuages par refroidissement par la base.....	19
1.7.5. Classification des nuages.....	19
1.8. Compositions colorées à partir des images MSG.....	22
1.9. Discussion.....	26

CHAPITRE 2 : ANALYSE ET SEGMENTATION D'IMAGES

2.1. Préambule	27
2.2. Analyse de l'image.....	28
2.2.1. Analyse statistique.....	28
2.2.1.1. Modélisation Markovienne.....	28
2.2.1.2. Analyse par extraction des paramètres.....	30
2.2.2. Analyse par transformation.....	30
2.2.3. Analyse par fractals.....	30
2.2.4. Analyse en composantes principales « ACP ».....	30
2.2.5. Analyse de l'homogénéité.....	31
2.3. Segmentation.....	31
2.4. Stratégies de segmentation.....	32
2.4.1. Les stratégies scalaires.....	32
2.4.2. Les stratégies marginales.....	33
2.4.3. Les stratégies vectorielles.....	33
2.5. Méthodes de Segmentation.....	34
2.5.1. Méthodes de détection de contour.....	34
2.5.1.1. Les méthodes dérivatives et techniques de filtrages.....	34
2.5.1.2. Approche morphologique.....	35
2.5.1.3. Rupture de modèle.....	35
2.5.2. Méthodes de segmentation en régions.....	36
2.5.2.1. Méthodes de segmentation par seuillage.....	36
2.5.2.2. Méthodes de classification.....	37
2.5.2.3. Approches par classification floue.....	41
2.5.2.4. Méthodes de segmentation par croissance de régions.....	42
2.5.2.5. Méthodes de segmentation par divisions et fusion de régions	42
2.6. Comparaison des méthodes de segmentation.....	43
2.7. Application à la segmentation d'images couleur texturées.....	45
2.8. Discussion.....	55

CHAPITRE 3 : SEGMENTATION LOCALE–SPECTRALE FLOUE

3.1. Problématique.....	56
3.2. Description de la méthode.....	57
3.2.1. Algorithme de classification local flou.....	57
3.2.1.1. Classification C-moyennes floue (FCM).....	58
3.2.1.2. Mesure de similarité spectral –local (SL) FCM.....	60
3.2.1.3. Classification (SL) FCM.....	63
3.2.2. Algorithme de fusion de régions.....	64
3.2.3. Algorithme de segmentation	65
3.3. Résultats et discussions.....	66
3.3.1. Application aux images synthétiques.....	66
3.3.2. Application aux images MSG.....	69
3.3.2.1. Présentation des données MSG.....	69
3.3.2.2. Discussion des résultats.....	74
3.4. Discussion.....	76

CHAPITRE 4 : SEGMENTATION PAR FILTRAGE DE GABOR ET ANALYSE D’HOMOGENÉITÉ LOCALE

4.1. Problématique.....	78
4.2. Description de la méthode.....	79
4.2.1. Extraction des attributs de texture.....	79
4.2.1.1. Caractérisation du canal.....	81
4.2.1.2. Choix des paramètres des filtres.....	82
4.2.1.3. Calcul des attributs de l’image.....	83
4.2.2. Classification des textures multispectrales.....	83
4.2.3. Analyse d’homogénéité locale.....	85
4.3. Résultats et discussions.....	87

4.3.1. Application aux images synthétiques.....87
4.3.2. Application aux images MSG.....95
4.4. Comparaison des résultats des deux approches LSF et FGAHL.....97
4.5. Discussion.....102

CONCLUSION ET PERSPECTIVES.....104

ANNEXES

Annexe A. Définition des concepts fondamentaux des ensembles flous.....105
A.1 Opérations ensemblistes : définitions originales de L. Zadeh.....105
A.2 α -cut.....106
Annexe B. Formalisme de la logique floue et de la classification floue.....107
B.1. Formalisme de la logique floue.....107
B.2. Formalisme de la classification nette et de la classification floue.....109

BIBLIOGRAPHIE

INTRODUCTION

Avec les progrès de l'électronique et de l'informatique, l'image est devenue un vecteur fondamental de l'information et de la communication. C'est ainsi, que l'image tient une place importante dans des secteurs divers et variés tels que la médecine, la biologie, la télédétection etc...

Au regard des progrès technologiques des capteurs et de la capacité des mémoires de stockage, un nombre énorme d'images multispectrales avec une résolution spectrale et spatiale très élevées sont produites à chaque instant.

L'image de télédétection tant aérienne que satellitaire est le modèle visuel le plus riche de l'espace géographique. Elle est la source d'informations abondantes et précises sur l'occupation du sol et sur les phénomènes qui se déroulent à la surface de la planète. Avec les images multispectrales des satellites Météosat Seconde Génération (MSG), de nombreuses perspectives et applications s'ouvrent à la recherche, tant dans les domaines de la climatologie que des activités connexes de surveillance de l'environnement telles que : l'hydrologie, l'agriculture, la détection des feux de forêts, le suivi des nuages...etc. Dans l'analyse d'images météorologiques, la détection des nuages est une opération importante dans le traitement de données météorologiques. Le problème de détection des différents types de nuages peut être résolu par l'analyse de l'imagerie satellitaire multispectrale telles les images collectées par le satellite MSG.

La segmentation est une étape primordiale en traitement d'images puisqu'elle conditionne la qualité de l'interprétation puis la prise de décision effectuée sur l'image plus tard. En effet, il s'agit d'extraire une information structurée de haut niveau permettant de reconnaître et d'indexer les images. La qualité de l'interprétation dépend fortement de celle de la segmentation.

Il n'existe pas de méthodes de segmentation universelles et le choix d'une technique est difficile puisqu'il est lié, notamment à la nature de l'image (éclairage, contours, texture,...), aux opérations en aval de la segmentation (compression, reconnaissance des formes, interprétation,

mesure), aux primitives à extraire (droites, régions, textures,...) mais aussi aux contraintes d'exploitation (temps réel, mémoire,...).

Malgré la grande diversité des méthodes utilisées, les résultats de segmentation demeurent modestes et ils varient beaucoup en fonction de la technique choisie. Ainsi, des erreurs de segmentation sont susceptibles d'intervenir comme : la sur-segmentation, qui génère des régions qui ne correspondent à aucun objet de la scène ou la sous-segmentation, qui ne distingue pas l'ensemble des objets de la scène. Généralement, dans le domaine de la segmentation automatique, la diversité des régions ne permet pas de segmenter convenablement celles-ci avec une seule méthode.

Avec l'apparition de capteurs plus performants, la scène est de mieux en mieux bien décrite par les données, par ailleurs la taille est de plus en plus importante (imagerie multi et hyper spectrale). Ainsi, les traitements deviennent de plus en plus fastidieux et compliqués à réaliser. La nature multispectrale des images ne permet pas d'utiliser directement les méthodes de traitement utilisées en niveaux de gris. Par conséquent, il est nécessaire d'élaborer de nouvelles méthodes de segmentation qui permettent de détecter les régions d'intérêt dans les images multispectrales.

Pour apporter une solution à la segmentation, plusieurs méthodes ont été proposées ces dernières années. Parmi ces méthodes, nous citons celles qui exploitent l'information spectrale dans les images [Dunn 1974 ; Gath et Geva 1989 ; Hathway et Bezdek 2001 ; Kurrugollu et al. 2001 ; Dooley et al. 2003 ; Qixiang et al. 2003 ; Thanh et al. 2003 ; Nuzillard et Lazar 2007 ; Huynh et Jong-Myon 2009 ; Kwork et al. 2009] et celles qui sont basées sur les caractéristiques spatiales de l'image [Mardia and Hainsworth 1988 ; Saarinen 1994 ; Colantini et Laget 2000 ; Noordam et al. 2000 ; Chuang et al. 2006 ; Cai et al. 2007; Gruia *et al.* 2007 ; Feng et Licheng 2011]. Cependant, ces méthodes utilisent généralement des stratégies de segmentation qui ne prennent pas en compte les corrélations spectrales et spatiales qui peuvent exister entre les pixels de l'image. D'où la nécessité d'élaborer de nouvelles méthodes de segmentation qui tiennent compte, conjointement, de l'information spatiale et vectorielle contenue dans les images multispectrales.

Dans cette thèse, notre intérêt est focalisé sur l'analyse et la segmentation d'images multispectrales, en particulier la segmentation d'images satellitaires météorologiques de type MSG. Ainsi, nous présenterons deux approches de segmentation d'images multispectrales. La

première, utilise une segmentation récursive basée sur la classification locale-spectrale floue et la fusion des régions. La deuxième est basée sur la classification floue des textures spectrales et l'analyse de l'homogénéité locale. Le but de ces deux méthodes est la détection des nuages dans les images satellitaire multipectrales MSG.

Cette thèse est structurée en quatre chapitres.

Dans le premier chapitre, dans un premier temps, nous expliquons le processus de la télédétection spatiale, l'interaction existante entre le rayonnement électromagnétique et l'atmosphère ainsi que l'interaction entre le rayonnement et la matière nécessaire à la compréhension de la nature des signatures spectrales des principales surfaces naturelles. Dans un deuxième temps, nous présentons les différentes caractéristiques des images MSG, et nous donnons les différents types de nuages existants. Enfin, nous exposons le principe de composition colorée à partir d'images MSG, permettant de produire des images en couleur en tenant compte de la signature spectrale des objets.

Le second chapitre, est consacré à l'état de l'art de l'analyse et de la segmentation d'images. Devant la diversité des méthodes auxquelles la littérature scientifique fait référence, le choix d'une stratégie de segmentation demeure un problème ardu. Ce chapitre est également consacré à une étude comparative des différentes méthodes de segmentation dans le but de justifier le choix de celles qu'il faut adopter.

Les chapitres trois et quatre sont consacrés au développement des deux méthodes que nous avons élaborées. Les deux techniques ont été appliquées à des images synthétiques et à des images satellitaires multispectrales de type MSG. Les résultats obtenus ont été discutés permettant ainsi de comparer les deux techniques et de quantifier leur apport.

En conclusion, nous avons rassemblé les principaux résultats et mis en relief la supériorité des techniques que nous avons élaborées en expliquant les principaux apports de celles-ci. Nous avons aussi donné les perspectives ouvertes par notre travail.

CHAPITRE 1

LES IMAGES MULTISPECTRALES MSG

1.1. Préambule

L'image de télédétection tant aérienne que satellitaire est le modèle visuel le plus riche de l'espace géographique. Elle est la source d'informations abondantes et précises sur l'occupation du sol et sur les phénomènes qui se déroulent à la surface de la planète. Avec les images des satellites Météosat Seconde Génération (MSG), de nombreuses perspectives et applications s'ouvrent à la recherche, telles que: l'hydrologie, l'agriculture, la détection des feux de forêts, le suivi des nuages ...etc. Les satellites de la série Météosat Seconde Génération (MSG), dont le premier est Météosat-8, emportent deux instruments: le radiomètre-imageur dans le visible et l'infrarouge en rotation amélioré (SEVIRI), et l'instrument géostationnaire de détermination du bilan radiatif de la terre (GERB). SEVIRI exploite plus de données que ses prédécesseurs, avec des résolutions spatiales, temporelles et spectrales plus poussées.

Au début de ce chapitre, nous exposons le processus de la télédétection spatiale. Nous expliquons, également, l'interaction existante entre le rayonnement électromagnétique et l'atmosphère. L'interaction entre la lumière et la matière, nécessaire à la compréhension de la nature des signatures spectrales des principales surfaces naturelles y est également abordée. Dans un deuxième temps, nous présentons les caractéristiques des images MSG et nous donnons les

différents types de nuages existants. A la fin du chapitre, nous exposons le principe des compositions colorées à partir d'images MSG, permettant de produire des images en couleur en tenant compte de la signature spectrale des objets.

1.2. La télédétection spatiale

La télédétection spatiale permet d'observer le système terre, océans, atmosphère, en s'appuyant sur des méthodes d'acquisition de l'information à distance. Ces méthodes sont basées sur les propriétés du rayonnement électromagnétique. Les capteurs satellitaires permettent de mesurer l'énergie réfléchie et/ou émise par la surface de la terre et les océans ou par l'atmosphère. Ils permettent aussi d'analyser et de suivre l'évolution de ces milieux au cours du temps. Le processus de la télédétection est donné par la figure 1.1 [E-cours].

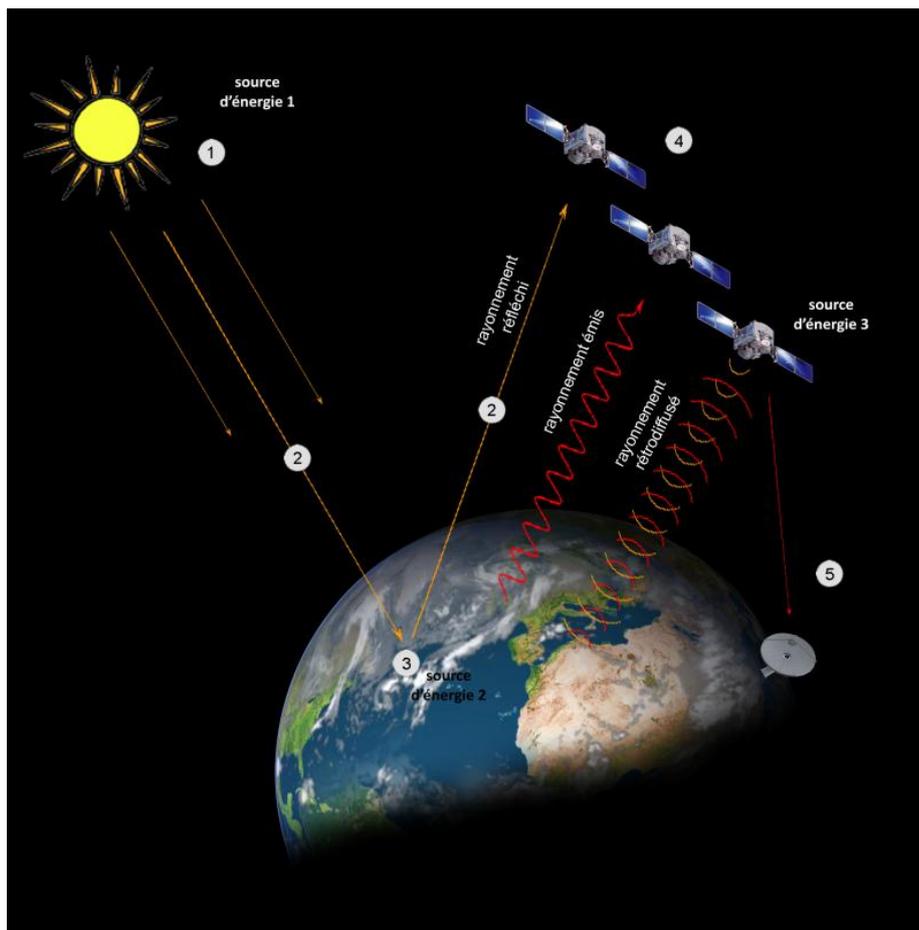


Figure 1.1. Processus de la télédétection

L'observation de la terre par les satellites peut être décomposée en cinq étapes :

1. La source d'énergie

Trois sources d'énergie sont utilisées en télédétection. La première, la plus commune est le soleil qui illumine la surface terrestre. La partie du rayonnement réfléchi par la surface de la terre est alors captée et enregistrée par le capteur satellitaire. La surface terrestre se comporte également comme source d'énergie en émettant un rayonnement qui peut être capté et enregistré par les capteurs satellitaires. Enfin, le capteur satellite peut lui-même être source d'énergie en émettant grâce à une antenne, un rayonnement vers la surface terrestre, puis en enregistrant la partie du rayonnement rétrodiffusée.

2. Les interactions du rayonnement avec l'atmosphère

Le rayonnement interagit avec l'atmosphère, lors de son trajet de la source d'énergie vers la surface terrestre puis de la surface vers le capteur satellitaire.

3. Les interactions du rayonnement avec la surface terrestre

Lorsque le rayonnement parvient à la surface de la terre, il va interagir avec celle-ci. La nature des interactions est fonction à la fois du rayonnement et des propriétés spectrales des surfaces.

4. L'enregistrement du signal par le capteur satellitaire

L'énergie réfléchi, émise ou rétrodiffusée par la surface de la terre est captée puis enregistrée et discrétisée au niveau du capteur satellitaire. On distingue deux types de capteurs en fonction de la source d'énergie.

- Pour caractériser les objets à la surface terrestre, les capteurs passifs utilisent les propriétés de réflexion du rayonnement solaire dans : le domaine optique, l'infrarouge thermique, et dans le domaine des micro-ondes.
- Dans les capteurs actifs, l'énergie est émise par le capteur lui-même dans le domaine des hyperfréquences puis rétrodiffusée par la surface terrestre.

5. La transmission et la réception des données

Le satellite transmet les données acquises à une station au sol. Ces données subissent alors les premiers traitements qui consistent à appliquer aux images brutes des corrections de type radiométrique et géométrique.

1.3. Le rayonnement électromagnétique

Le rayonnement électromagnétique correspond à l'ensemble des radiations émises par une source d'énergie qui peut être soit le soleil, ou bien encore le capteur satellitaire lui-même. Les radiations sont émises sous forme d'ondes électromagnétiques ou de particules.

Le spectre électromagnétique, donné par la figure 1.2 [E-cours], représente la répartition des ondes électromagnétiques en fonction de leur longueur d'onde.

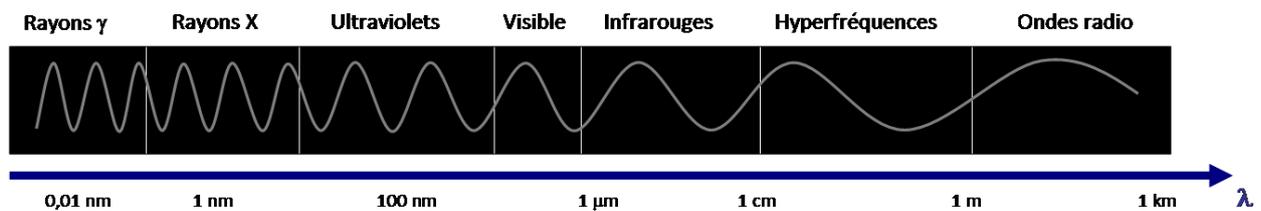


Figure 1.2. Spectre électromagnétique

En télédétection spatiale trois fenêtres spectrales sont principalement utilisées :

- Le domaine du visible.
- Le domaine des infrarouges (proche IR, IR moyen et IR thermique).
- Le domaine des micro-ondes ou hyperfréquences.

1.3.1. Le domaine du visible

La fenêtre du visible qui s'étend entre $0,4\mu\text{m}$ et $0,7\mu\text{m}$ est la seule fenêtre du spectre électromagnétique qui est perceptible par l'œil humain. La portion du spectre visible qui permet de visualiser les couleurs est donnée par la figure 1.3 [Compositions colorées].

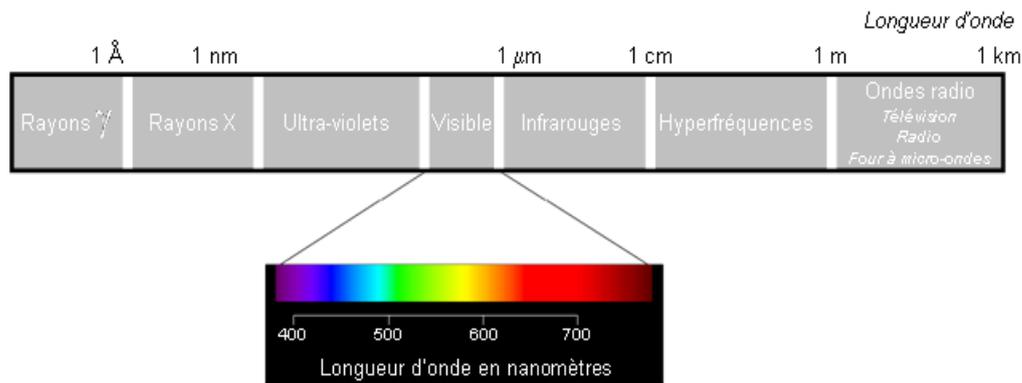


Figure 1.3. Domaine du visible du spectre électromagnétique

La décomposition de la lumière blanche émise par le soleil par un prisme, donne les couleurs constituantes qui vont du violet au rouge en passant par le bleu, le vert, le jaune et l'orange. La table 1.1 [Compositions colorées] donne les longueurs d'onde et fréquences des couleurs du spectre visible.

Table 1.1. Longueurs d'onde et fréquences des couleurs du spectre visible.

Couleur		longueur d'onde (1 nm – 10 ⁹ m)	Fréquence GHz
violet		380 à 450 nm	725
bleu		450 à 490 nm	640
vert		490 à 570 nm	565
jaune		570 à 585 nm	520
orange		585 à 620 nm	500
rouge		620 à 670 nm	465

1.3.2. L'infrarouge

Le domaine de l'infrarouge est relativement étendu puisqu'il couvre les longueurs d'onde de 0,7μm à 100μm. Dans cette fourchette de longueurs d'onde, on distingue différents types d'infrarouges qui vont du proche infrarouge à l'infrarouge lointain, en passant par l'infrarouge moyen et le thermique.

➤ **Le proche infrarouge**

Le proche infrarouge (0,7 μ m à 1,6 μ m) est la partie du spectre électromagnétique qui vient juste après le visible (couleur rouge). Les surfaces naturelles se distinguent par une forte réflectance dans les longueurs d'onde du proche infrarouge, alors qu'elles réfléchissent peu le rayonnement dans le visible.

➤ **L'infrarouge moyen**

L'infrarouge moyen (1,6 μ m à 4 μ m) permet, de façon générale, d'étudier les teneurs en eau des surfaces. Il est très utilisé en foresterie et en agriculture, notamment pour cartographier les couverts végétaux.

➤ **L'infrarouge thermique**

Dans ce domaine spectral (4 μ m à 15 μ m), le rayonnement dépend des propriétés d'émissivité des surfaces. En effet, une partie du rayonnement visible et proche infrarouge parvenant à la surface de la terre, est réémise sous forme de chaleur.

1.3.3. Les hyperfréquences

Ce domaine du spectre (1cm à 1m) est utilisé dans les capteurs Radar et les radiomètres à micro-ondes passives. L'atmosphère est quasiment transparente à ces longueurs d'onde qui traversent sans problème les couches nuageuses. Il est utilisé notamment en océanographie pour l'étude des glaces de mer et la détection des nappes d'hydrocarbures.

1.4. Le rayonnement et l'atmosphère

Le soleil et la surface terrestre émettent chacun un rayonnement électromagnétique comparable à celui d'un corps noir. Pour rappel, un corps noir est un corps qui absorbe tout le rayonnement qu'il reçoit et émet en retour un rayonnement thermique de manière à équilibrer le bilan radiatif. La distribution spectrale de son émission dépend alors uniquement de sa température et obéit à la loi de Planck :

$$B(T) = \frac{2hv^3}{c^2} \cdot \frac{1}{e^{\left(\frac{hv}{KT}\right)} - 1} \quad (1.1)$$

La fréquence du rayonnement est ν et T la température. La distribution du rayonnement solaire correspond approximativement à celle d'un corps noir à une température de 5800K à laquelle s'ajoute une série de raies d'absorption et d'émission dues aux éléments chimiques présents dans l'atmosphère solaire. L'émission solaire a essentiellement lieu de l'ultraviolet au proche infrarouge et est maximale dans le visible. L'émission terrestre s'apparente à celle d'un corps noir à la température de 288K et est maximale dans l'infrarouge thermique. La figure 1.4 [La télédétection spatiale] montre la distribution spectrale approximative du rayonnement solaire et terrestre. Les domaines de longueur d'onde des émissions sont presque totalement distincts, ce qui permet de différencier aisément chaque source.

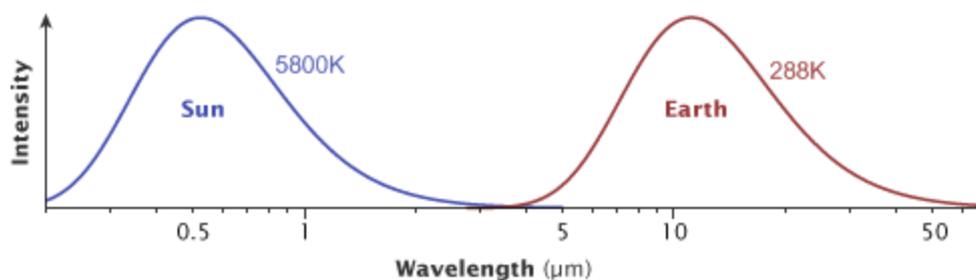


Figure 1.4. Distribution spectrale de l'émission de corps noirs à la température du soleil (bleu) et de la surface terrestre (rouge).

Lors de son trajet depuis la source (le soleil) vers la cible (surface terrestre), puis de la cible vers le capteur, le rayonnement électromagnétique subit des interactions avec les molécules gazeuses et les particules (aérosols, gouttelettes d'eau, poussières) présentes dans l'atmosphère. Deux phénomènes essentiels se produisent : l'absorption et la diffusion atmosphériques.

1.4.1. Absorption et émission atmosphérique

Lorsque le rayonnement traverse la couche atmosphérique, il entre en collision avec les molécules et les particules présentes dans l'atmosphère. Il peut être dévié de sa trajectoire, c'est le phénomène de diffusion atmosphérique, ou bien être en totalité ou en partie absorbé. Dans ce

dernier cas, il y a transfert d'énergie entre le rayonnement et les molécules avec lesquelles il entre en collision. L'absorption du rayonnement qui cède tout ou une partie de son énergie conduit par conséquent à une atténuation du signal dans la direction de propagation du rayonnement. La molécule change de configuration électronique. L'énergie absorbée modifie l'énergie interne de la molécule en la faisant passer d'un niveau d'énergie E_1 à un niveau d'énergie E_2 supérieur.

1.4.2. Diffusion atmosphérique

Lors de sa traversée atmosphérique, le rayonnement peut interagir avec les particules et les molécules présentes dans l'atmosphère qui constituent des obstacles à la propagation de l'énergie. Lorsque le rayonnement n'est pas absorbé, il peut être en partie dévié dans toutes les directions. C'est le phénomène de diffusion atmosphérique dont la nature dépend de plusieurs paramètres :

1. la longueur d'onde du rayonnement
2. la densité et la taille des particules et des molécules atmosphériques
3. l'épaisseur de la couche atmosphérique à traverser.

On distingue ainsi trois types de diffusion :

➤ La diffusion de Rayleigh

La diffusion de Rayleigh est due aux molécules gazeuses présentes dans l'atmosphère (O_2 , N_2 , CO_2 , vapeur d'eau, *etc.*) ou aux fines particules de poussière. Elle se produit lorsque la taille des molécules diffusantes est très inférieure à la longueur d'onde du rayonnement. La diffusion de Rayleigh est un phénomène sélectif qui se produit surtout pour les longueurs d'onde les plus courtes du spectre (violet, bleu).

Elle affecte les hautes couches de l'atmosphère et c'est elle qui explique la couleur bleue du ciel pendant la journée. Les longueurs d'ondes les plus courtes (bleu) du rayonnement solaire sont plus diffusées que les longueurs d'onde plus grandes (rouge), aussi le ciel apparaît bleu à l'observateur.

➤ **La diffusion de Mie**

Lorsque la taille des particules est de l'ordre de grandeur ou plus grande que la longueur d'onde du rayonnement, la diffusion de Rayleigh ne se produit plus et laisse la place à la diffusion de Mie. Les gouttelettes d'eau, les cristaux de glace, ou les aérosols présents dans l'atmosphère (poussières, fumées, pollens) sont les principaux vecteurs de la diffusion de Mie. Beaucoup moins sélective que la diffusion de Rayleigh, la diffusion de Mie est inversement proportionnelle à la longueur d'onde du rayonnement incident. Elle se produit plutôt dans les couches basses de l'atmosphère (qui contiennent plus d'aérosols) et donne à la couleur du ciel un aspect bleu délavé voire jaunâtre, toutes les longueurs d'onde étant diffusées de la même façon.

➤ **La diffusion non sélective**

La diffusion non sélective se produit lorsque la taille des particules atmosphériques est beaucoup plus grande que la longueur d'onde du rayonnement. Elle est due notamment aux gouttelettes d'eau que l'on trouve dans les nuages et les brouillards. La diffusion non sélective affecte toutes les longueurs d'onde, ce qui explique la couleur blanche des nuages.

1.5. Le rayonnement et la matière

Lorsque le soleil éclaire la surface terrestre, des interactions se produisent entre le rayonnement et la cible illuminée. En fonction des propriétés et des caractéristiques de la cible, une partie du rayonnement est réfléchi. Chaque objet ou chaque surface possède ainsi une réponse spectrale bien précise à une longueur d'onde donnée. L'ensemble des réponses spectrales à différentes longueurs d'onde constitue ce que l'on appelle la signature spectrale d'une surface. Chaque type de surface peut ainsi être caractérisé et identifié sur une image.

1.5.1. Les interactions entre le rayonnement et la matière

Lorsqu'un rayonnement électromagnétique atteint un objet, certaines longueurs d'onde sont absorbées tandis que d'autres sont réfléchies par l'objet. Une partie du rayonnement peut éventuellement être transmise à travers l'objet si celui-ci est plus ou moins transparent, avec un

changement de direction de la propagation dû à la réfraction. Ces différentes interactions sont représentées sur la figure 1.5 [E-cours]. Les objets sont caractérisés par un coefficient d'absorption (α), un coefficient de réflexion (ρ), et un coefficient de transmission (τ), qui expriment respectivement la part d'énergie absorbée, réfléchi et transmise.

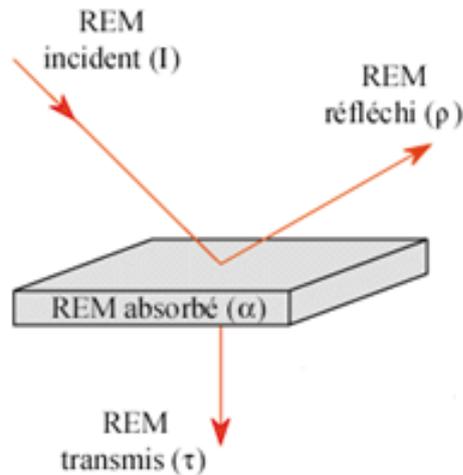


Figure 1.5. Interactions du rayonnement électromagnétique avec la matière

1.5.2. Les signatures spectrales des principales surfaces naturelles

En fonction de la nature et des caractéristiques intrinsèques des objets et des surfaces, le rayonnement incident interagira avec la cible selon l'une ou l'autre des propriétés citées précédemment. La signature spectrale d'un objet correspond à la quantité d'énergie réfléchi ou émise en fonction de la longueur d'onde. Ainsi, chaque surface possède une signature spectrale qui lui est propre et qui permettra son identification sur les images satellitaires. La figure 1.6 [E-cours] présente les signatures spectrales des surfaces naturelles dans le domaine du visible, du proche infrarouge, et de l'infrarouge moyen.

1. En ce qui concerne la signature spectrale des sols, on note un accroissement régulier de la réflectance au fur et à mesure qu'on se déplace vers les grandes longueurs d'onde.
2. La végétation a une réflectance très forte dans le proche infrarouge, elle diminue dans le visible et l'infrarouge moyen.

3. L'eau a une réflectance très faible dans toutes les longueurs d'onde, elle absorbe cependant un peu moins les ondes les plus courtes.
4. La neige a une réflectance très forte dans les ondes courtes, mais elle diminue rapidement dans le proche infrarouge, pour atteindre des valeurs très faibles dans l'infrarouge moyen où le rayonnement est absorbé par l'eau.

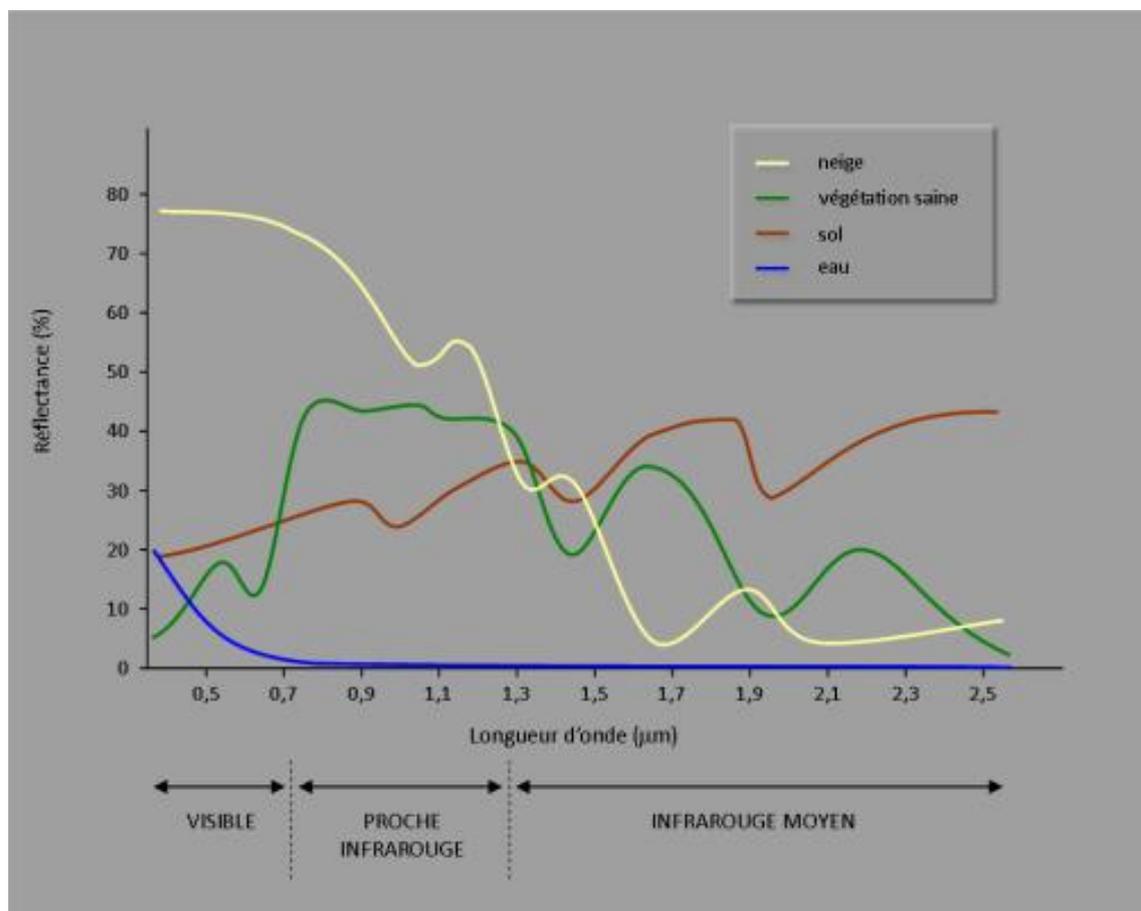


Figure 1.6. Signatures spectrales des surfaces naturelles dans le domaine du visible, du proche infrarouge et de l'infrarouge moyen.

1.6. Caractéristiques des images MSG

L'instrument principal, le radiomètre imageur SEVERI, transmet des images de l'hémisphère terrestre tous les quarts d'heure dans douze bandes spectrales différentes. SEVERI fournit des images avec une résolution spectrale, spatiale, et temporelle très poussés.

A titre de comparaison, les capteurs Météosat de la première génération ne disposaient que de trois canaux spectraux et transmettaient les images du globe toutes les trente minutes. La résolution spatiale est également améliorée, puisqu'elle est de 3km pour les bandes multispectrales (contre 5km pour la première génération) et de 1km pour le canal visible haute résolution HRV (contre 2,5km auparavant). Les performances de SEVERI permettent aux météorologistes de décrire plus précisément les processus atmosphériques.

Les 11 premiers canaux de SEVERI effectuent une rotation complète du disque terrestre toutes les 15 minutes. Le pas d'échantillonnage est approximativement de 3 km au point sous le satellite. Ce pas détermine la résolution des images prises dans tous ces canaux. Le 12^{ème} canal de SEVERI, avec une grande résolution dans le visible (HRV), a une résolution nominale d'approximativement de 1 km au point sous le satellite. Dans le canal HRV, la rotation couvre toute la dimension Nord-Sud et une partie seulement de la dimension Est-Ouest. Les images sont aussi transmises toutes les 15 minutes. La figure 1.7 [E-cours] montre des images prises dans les douze canaux de l'instrument SEVERI.

La table 1.2 [EUMETSAT, 2005] donne les caractéristiques et les objectifs principaux des 12 canaux de l'imagerie SEVERI. La figure 1.7 présente l'ensemble des douze bandes spectrales de MSG depuis les longueurs d'onde du visible jusqu'à l'infrarouge thermique. La figure 1.8 [E-cours] donne la répartition des bandes MSG sur le spectre électromagnétique.

Table 1.2. Caractéristiques et objectifs principaux des 12 canaux de prise d'images de SEVERI

Canal	Appellation	Longueur d'onde centrale (μm)	Objectif principal
C1	VIS 0.6	0.635	Surface, nuages, champs de vent
C2	VIS 0.8	0.81	Surface, nuages, champs de vent
C3	NIR 1.6	1.64	Surface, phase du nuage
C4	IR 3.9	3.90	Surface, nuages, champs de vent
C5	WV 6.2	6.25	Vapeur d'eau, nuages à haute altitude, instabilité atmosphérique
C6	WV 7.3	7.35	Vapeur d'eau, instabilité atmosphérique
C7	IR 8.7	8.70	Surface, nuages, instabilité atmosphérique
C8	IR 9.7	9.66	Ozone
C9	IR 10.8	10.80	Surface, nuages, champs de vent, instabilité atmosphérique
C10	IR 12.0	12.00	Surface, nuages, instabilité atmosphérique
C11	IR 13.4	13.40	Hauteur des Cirrus
C12	HRV	0.4 – 1.1 μm	Surface, nuages

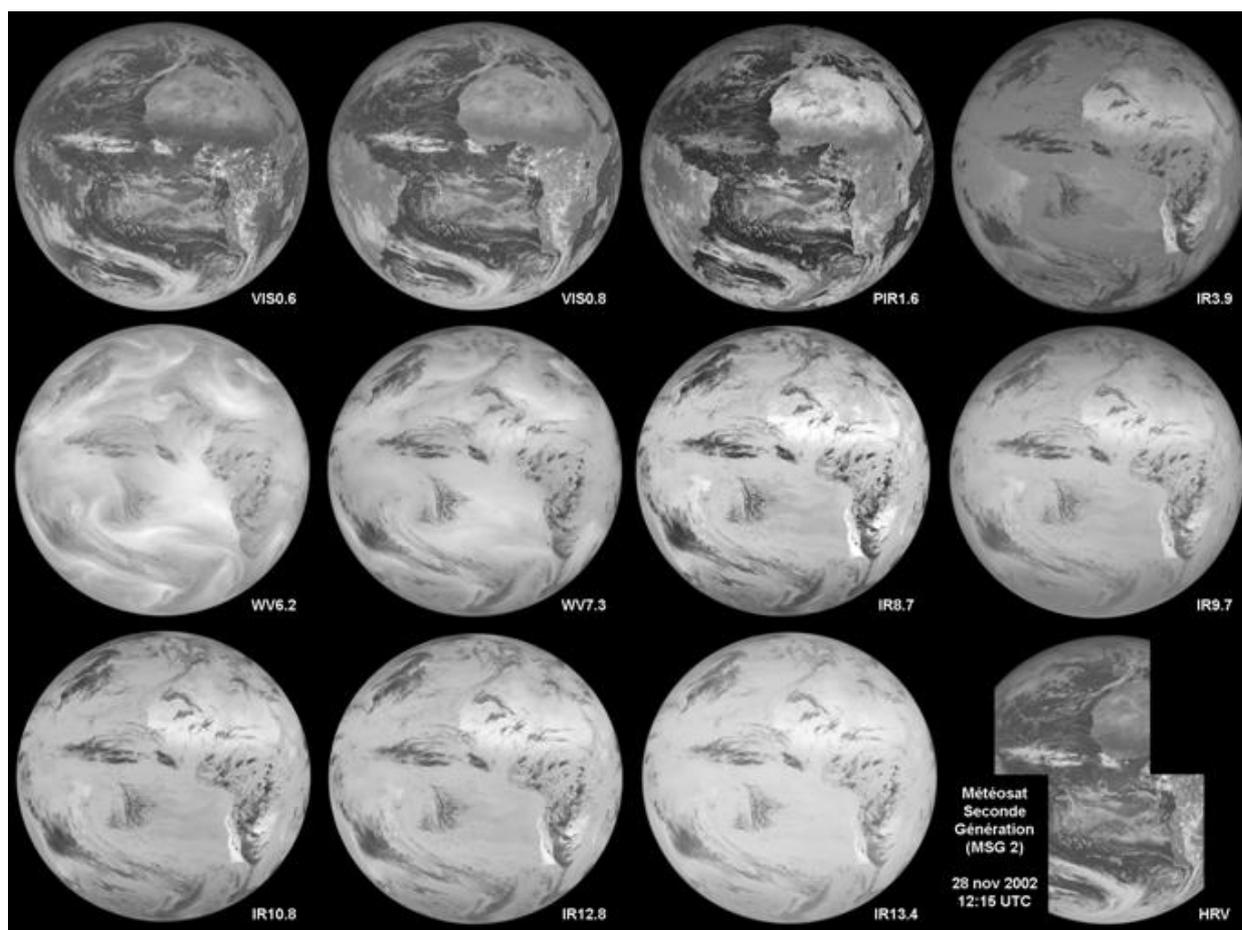


Figure 1.7. Les douze bandes spectrales de SEVERI

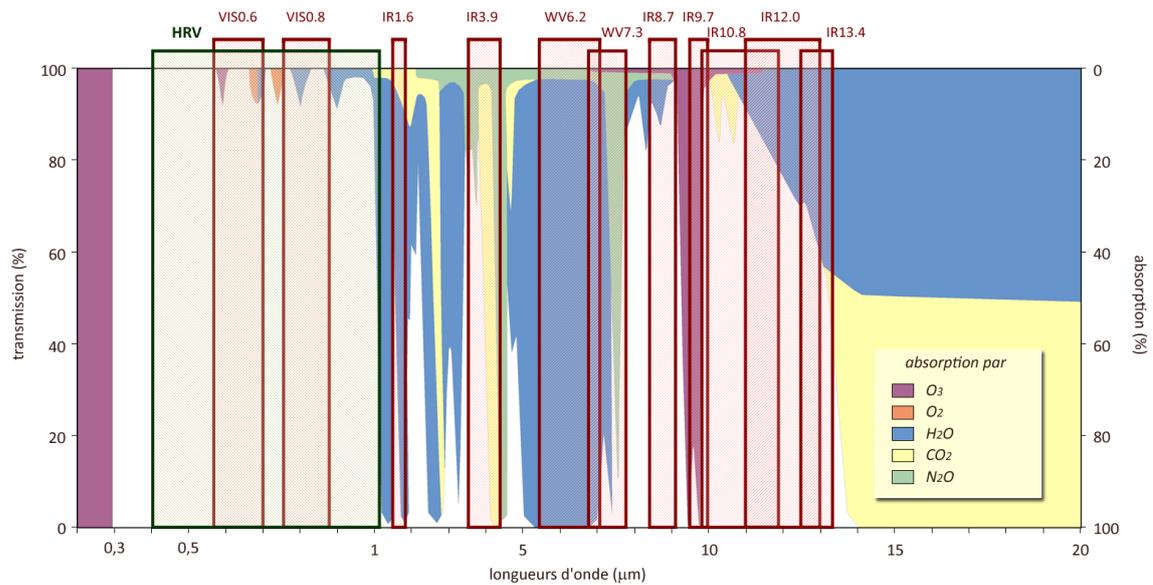


Figure 1.8. Répartition des bandes MSG sur le spectre électromagnétique

1.7. Formation et classification des nuages

Un nuage est formé d'un ensemble de gouttelettes d'eau ou de cristaux de glace en suspension dans l'air. L'aspect du nuage dépend de la lumière qu'il reçoit et des particules qui le constituent. Un nuage se forme par condensation de la vapeur d'eau lorsque l'air humide se refroidit. Nous pouvons classer les nuages en fonction du processus physique de leur formation : soulèvement orographique, convection, soulèvement frontal, refroidissement par la base.

1.7.1. Formation des nuages par soulèvement orographique

Le soulèvement d'une masse d'air jusqu'à un niveau supérieur à son niveau de condensation provoque la formation de nuages. Le relief oblige la masse d'air à s'élever sur sa face au vent. La masse d'air s'élevant, sa température s'abaisse et peut atteindre le seuil de saturation. Un nuage se forme alors sur le versant au vent et se dissipe sur le versant sous le vent.

1.7.2. Les nuages de convection

Le réchauffement du sol se communique à l'air qui, dilaté donc plus léger, se met à monter et se refroidit par détente. Les nuages de convection apparaissent d'autant plus facilement qu'il y a de l'air froid en altitude. Les bases de tels nuages sont horizontales, leurs sommets évoluent en fonction de la température. Ils sont fréquents l'été sur terre, l'hiver sur mer.

1.7.3. Formation des nuages par soulèvement frontal

Dans une perturbation en mouvement, l'air chaud est soulevé à l'avant par la masse d'air froid antérieur (front chaud). L'air froid postérieur rejette l'air chaud en altitude (front froid). Le long des fronts se forment les nuages.

1.7.4. Formation des nuages par refroidissement par la base

Quand l'air chaud et humide en provenance de la mer arrive en contact avec une surface froide, il se refroidit. Ce mécanisme conduit à la formation de nuages bas ou brouillards. Il est fréquent l'hiver à l'approche de l'air doux et humide venant de l'Atlantique. On l'observe l'été en mer lorsque de l'air relativement doux arrive sur des eaux froides.

1.7.5. Classification des nuages

La classification des nuages utilisée est essentiellement basée sur l'existence de dix groupes principaux, appelés « genres ». Les différents genres de nuages sont classés en fonction de leur altitude :

- A l'étage supérieur (de 5 à 12 km d'altitude), on retrouve le cirrus, le cirrocumulus et le cirrostratus, composés de cristaux de glace.

- A l'étage moyen (de 2 à 5 km d'altitude), l'altocumulus et l'altostratus.

- A l'étage inférieur (du sol à 2000 m d'altitude), le stratus et le stratocumulus.
- Le nimbostratus, le cumulus et le cumulonimbus sont des nuages à développement vertical important et occupent donc plusieurs 'étages'.

La figure 1.9 montre les différents genres de nuages avec leurs altitudes [Comprendre la météo].

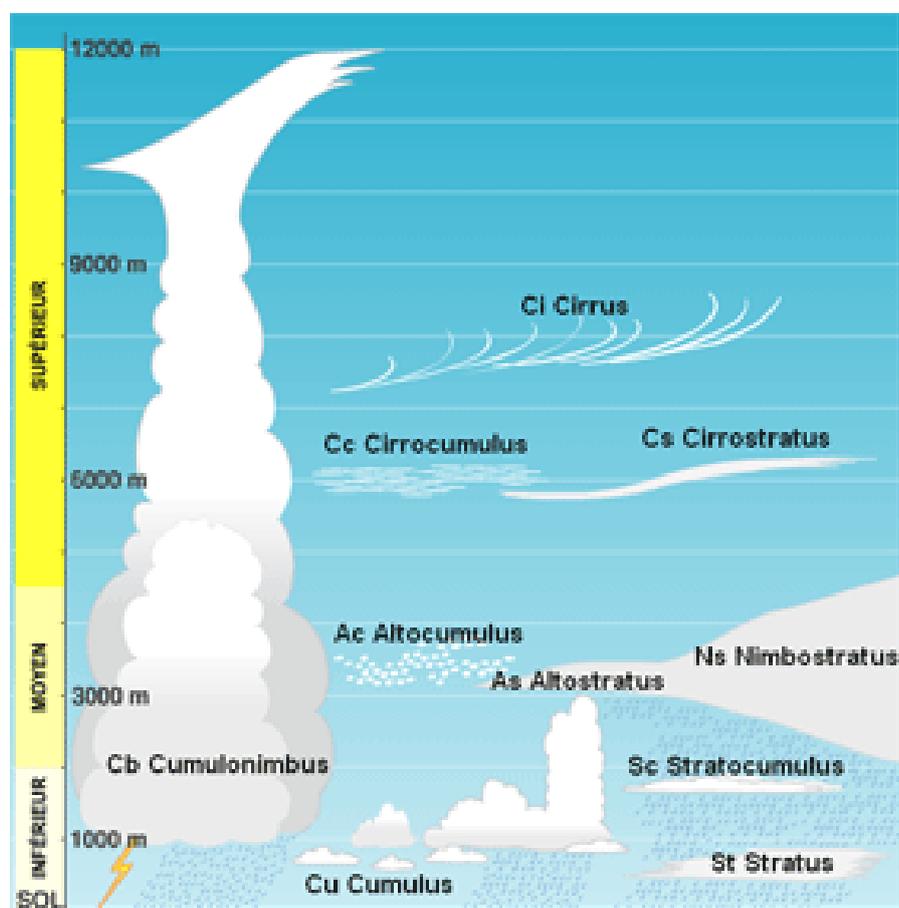


Figure 1.9. Les différents types de nuages.

Cirrus

Nuages séparés, en forme de filaments blancs et délicats ou de bancs ou de bandes étroites, blancs ou en majeure partie blancs. Ces nuages ont un aspect fibreux (chevelu) ou un éclat soyeux, ou les deux.

Cirrocumulus

Banc, nappe ou couche mince de nuages blancs, sans ombres propres, composés de très petits éléments en forme de granules, de rides, ...etc, soudés ou non, et disposés plus ou moins régulièrement.

Cirrostratus

Voile nuageux transparent et blanchâtre, d'aspect fibreux (chevelu) ou lisse, couvrant entièrement ou partiellement le ciel, et donnant généralement lieu à des phénomènes de halo.

Altostratus

Nappe ou couche nuageuse grisâtre ou bleuâtre, d'aspect strié, fibreux ou uniforme, couvrant entièrement ou partiellement le ciel, et présentant parfois des parties suffisamment minces pour laisser voir le soleil au moins vaguement, comme au travers d'un verre dépoli. L'Altostratus ne présente pas de phénomènes de halo et peut être accompagné de pluie ou de neige.

Alto cumulus

Banc, nappe ou couche de nuages blancs ou gris, ou à la fois blancs et gris, ayant généralement des ombres propres, composés de lamelles, galets, rouleaux, etc., d'aspect parfois partiellement fibreux ou diffus, soudés ou non.

Nimbostratus

Couche nuageuse grise, souvent sombre, dont l'aspect est rendu flou par des chutes plus ou moins continues de pluie ou de neige qui, dans la plupart des cas, atteignent le sol. L'épaisseur de cette couche est partout suffisante pour masquer complètement le soleil. Il existe fréquemment, au-dessous de la couche et la rendant difficilement visible, des nuages bas déchiquetés.

Stratocumulus

Banc, nappe ou couche de nuages gris ou blanchâtres, ayant presque toujours des parties sombres, composés de dalles, galets, rouleaux, etc., d'aspect non fibreux, soudés ou non.

Stratus

Couche nuageuse généralement grise, à base assez uniforme, pouvant donner lieu à de la bruine ou à de la neige en grains. Lorsque le soleil est visible au travers de la couche, son contour est

nettement discernable. Le Stratus ne donne pas lieu à des phénomènes de halo sauf à de très basses températures. Le Stratus peut aussi se présenter sous la forme de bancs déchiquetés.

Cumulus

Nuages séparés, généralement denses et à contours blancs bien délimités, se développant verticalement en forme de mamelons, de dômes ou de tours, dont la région supérieure bourgeonnante ressemble souvent à un chou-fleur. Les parties de ces nuages éclairées par le soleil sont, le plus souvent, d'un blanc éclatant; leur base, relativement sombre, est sensiblement horizontale.

Cumulonimbus

Nuage dense et puissant, à extension verticale considérable, en forme de montagne ou d'énormes tours. Une partie au moins de sa région supérieure est généralement lisse, fibreuse ou striée, et presque toujours visible; cette partie s'étale en forme d'enclume ou de vaste panache. Au dessous de la base de ce nuage, souvent très sombre, il existe fréquemment des nuages bas déchiquetés, soudés ou non avec elle, et des précipitations de tous genres.

1.8. Compositions colorées à partir d'images MSG

Les compositions colorées permettent de produire des images en couleurs en tenant compte de la signature spectrale des objets. L'objectif est de distinguer les différents types de surfaces sur les images multispectrales MSG, afin d'en faciliter l'interprétation. La réalisation d'une composition colorée consiste à affecter à chacune des trois couleurs primaires (le rouge, le vert et le bleu) trois bandes spectrales du capteur SEVERI. Par synthèse additive, les couleurs peuvent être reconstituées.

Avec le capteur SEVERI, il n'est pas possible de réaliser des compositions en « vraies couleurs ». En effet, le capteur SEVERI ne dispose que d'une seule bande spectrale dans le domaine visible (VIS 0.6), centrée sur le rouge. Dans une image en 'vraies couleurs', on affecte aux bandes spectrales acquises dans les longueurs d'onde du bleu, du vert et du rouge, les trois couleurs primaires correspondantes. L'image résultante correspond donc exactement à ce qu'un observateur pourrait observer s'il se trouvait à bord du satellite.

Avec les onze bandes spectrales, un grand nombre de compositions colorées peuvent être réalisées. Mais en règle générale, on ne combine que les bandes spectrales qui présentent des propriétés physiques différentes.

La table 1.3 donne quelques exemples de combinaisons standards recommandées par EUMETSAT [E-cours] pour étudier les surfaces terrestres et suivre certains phénomènes naturels.

Table 1.3. Compositions colorées standards utilisées avec le satellite MSG

Composition RVB	Applications	Jour/nuit
IR1.6/VIS0.8/VIS0.6	Nuages, Végétation, brouillard, neige, fumées.	Jour
VIS0.8/IR3.9/IR10.8	Nuages, convection, neige, brouillard, incendie	Jour
VIS0.8/IR1.6/IR3.9	Neige, brouillard	Jour
IR3.9/IR1.6/VIS0.6	Végétation, incendie, fumée, nuages	Jour
WV6.2-WV7.3/IR3.9-IR10.8/IR1.6-VIS0.6	Convection	Jour
IR12.0-IR10.8/IR10.8-IR8.7/IR10.8	Poussières (tempête de sable)	Jour et Nuit
IR12.0-IR10.8/IR10.8-IR3.9/IR10.8	Nuages, brouillard	Jour

L'image de la figure 1.10, présente une composition en « fausses couleurs » réalisée à partir des bandes spectrales IR1.6, VIS0.8, et VIS0.6 du satellite MSG. Cette image a été construite en assignant les canaux IR 1.6, VIS 0.8, VIS 0.6 aux composantes rouge, vert, et bleue, respectivement.

Les images MSG dans les canaux visibles et infrarouges, ont été collectées durant le mois de février 2012 par l'office national de la météorologie à Dar El Beida à Alger.

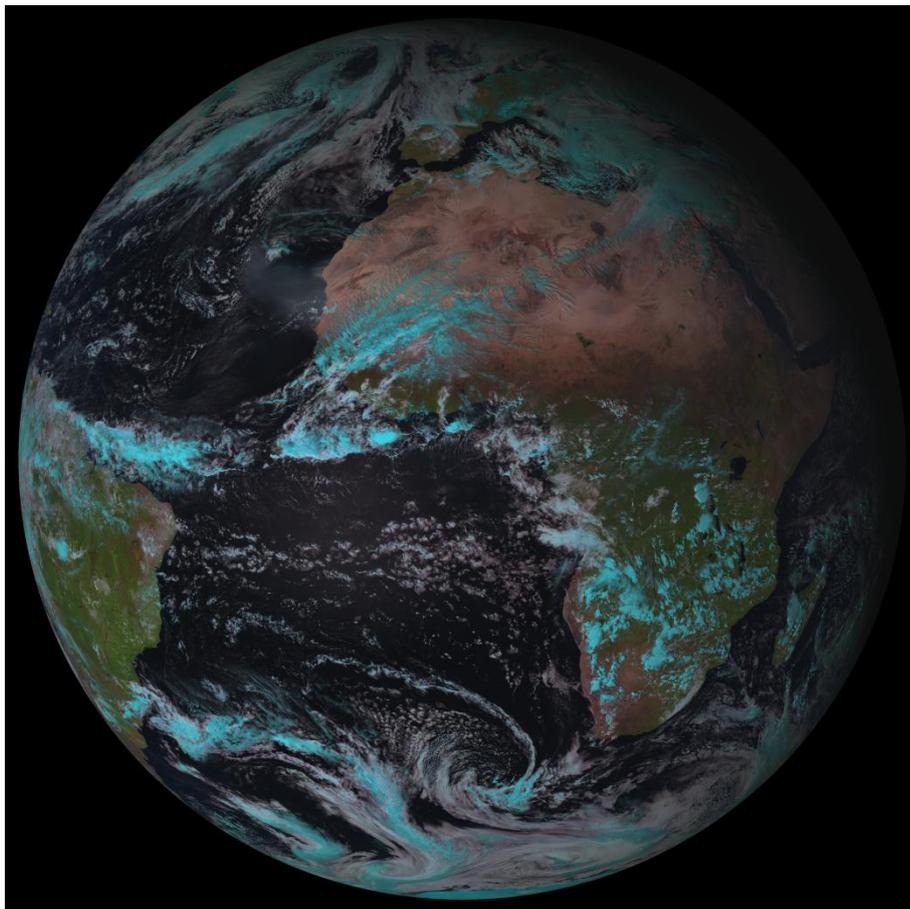


Figure 1.10. Image MSG composite en fausses couleurs réalisée à partir des bandes 321, acquise le 06 février 2012 à 14H

La figure 1.11 illustre le principe de composition colorée, permettant de réaliser l'image précédente, à partir de trois bandes spectrales de MSG:

- le canal IR1.6 (proche infrarouge) est codé en rouge,
- le canal VIS0.8 (visible) est codé en vert
- et le canal VIS0.6 (visible) est codé en bleu.

Les couleurs résultantes sont fonction des valeurs numériques des pixels dans chacune des trois bandes spectrales.

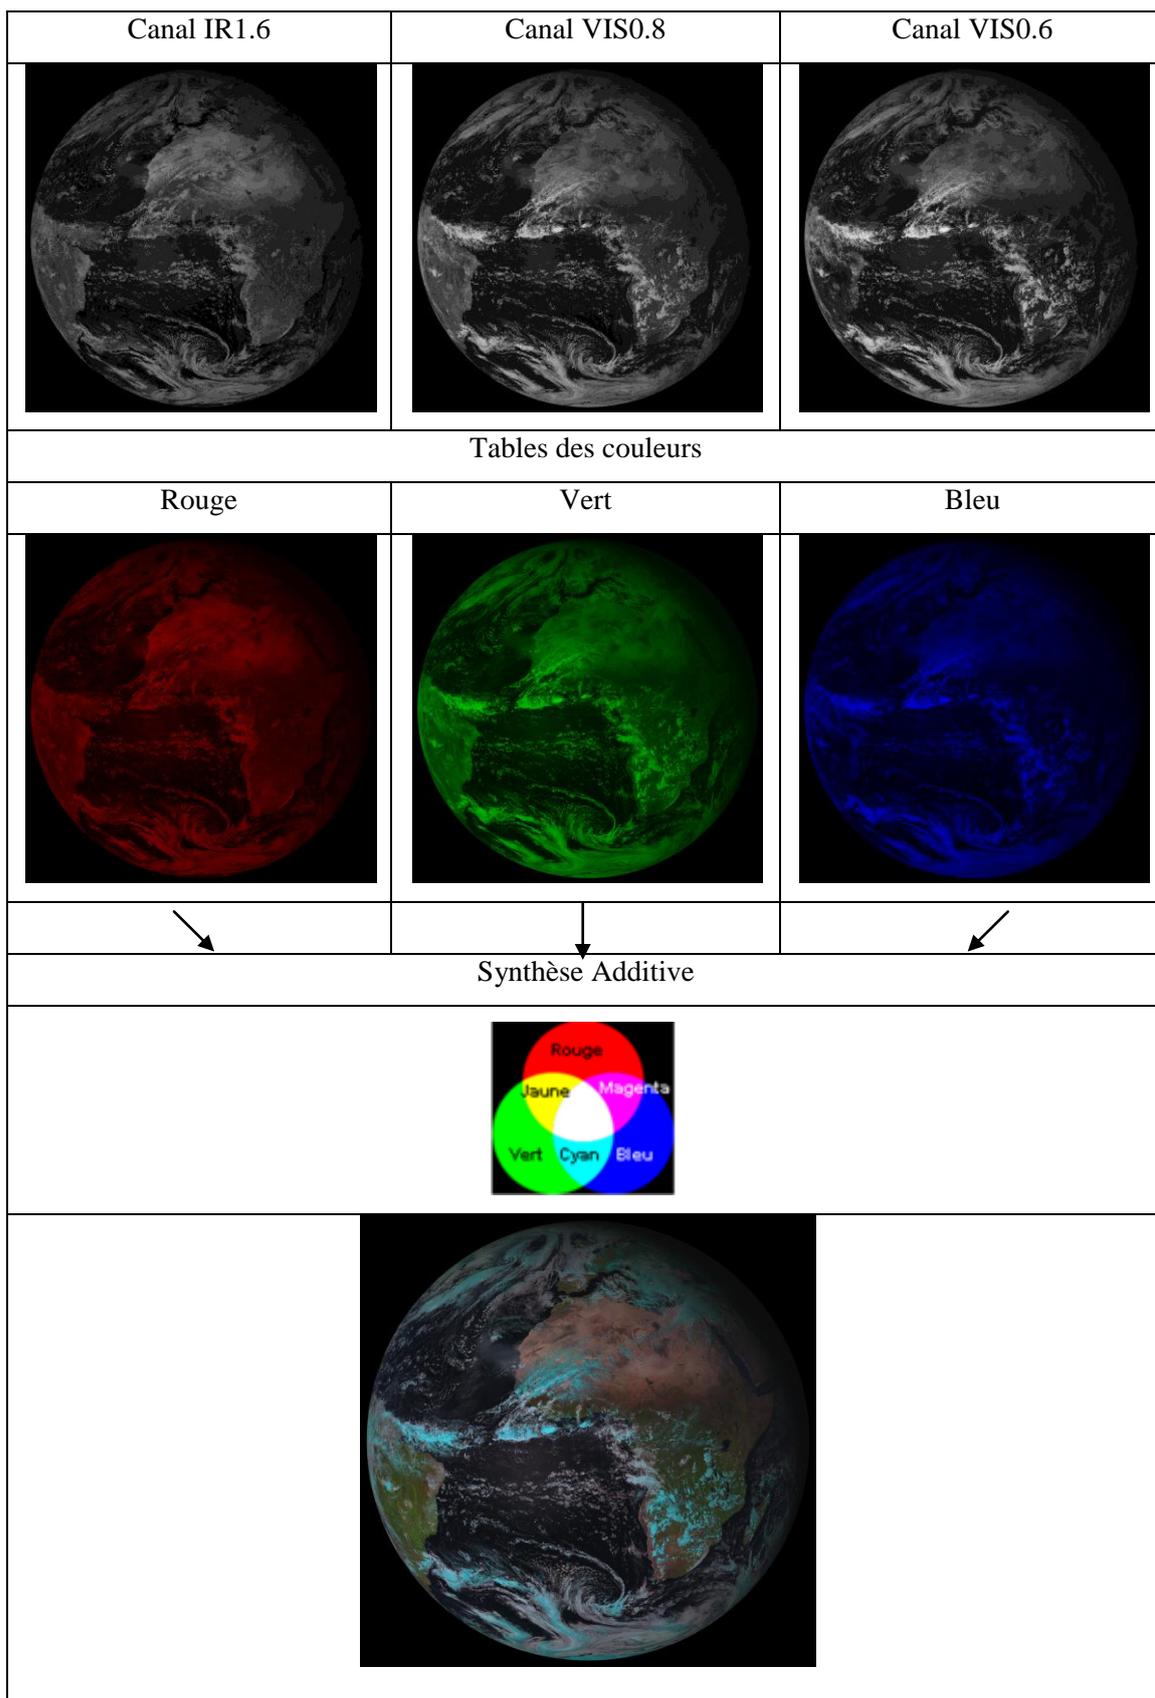


Figure 1.11. Principe de composition colorée à partir des trois bandes spectrales IR1.6, VIS0.8, et VIS0.6.

1.9. Discussion

Dans ce chapitre, nous avons exposé le processus de la télédétection spatiale, où nous avons mis en relief l'interaction existante entre le rayonnement et l'atmosphère. En effet, ce sont les constituants de l'atmosphère qui confèrent, au système Soleil-Atmosphère-Terre, un caractère aléatoire, car s'il n'avait pas d'atmosphère, ce système aurait été complètement déterminé. Notons que parmi ces constituants les nuages restent les principaux perturbateurs. Ensuite, nous avons montré l'interaction qui existe entre le rayonnement et la matière ainsi que l'effet de celle-ci sur la signature spectrale dans les surfaces de scènes naturelles. Ainsi la connaissance de ces signatures permet d'identifier chaque type de surface et chaque type de nuage. Dans un deuxième temps, nous avons donné les caractéristiques principales de l'imagerie MSG, ce qui a permis de mettre en évidence les propriétés spatiales, temporelles et spectrales du radiomètre imageur SEVERI. Enfin, nous avons aussi montré que la composition colorée, à partir des différentes bandes spectrales, permet de mettre en évidence les différentes classes constituant l'image à traiter. Cette composition colorée peut également être utilisée pour une interprétation de l'image.

CHAPITRE 2

ANALYSE ET SEGMENTATION D'IMAGES

2.1. Préambule

L'analyse d'images a pour but l'extraction de l'information caractéristique contenue dans une image. Cette analyse donne une description structurelle de l'image, qui peut prendre la forme d'une image ou de toute structure de données (niveaux de gris, couleur, forme, texture...). L'analyse d'images fait appel à la segmentation où l'on va associer à chaque pixel un label. La segmentation consiste à créer une partition de l'image en régions homogènes, afin d'en extraire des informations particulières. La segmentation dépend de la nature de l'image et de l'objectif recherché. Par conséquent, il convient d'analyser les images avant de définir une méthode de segmentation appropriée.

Dans ce chapitre, nous présentons tout d'abord les principales approches d'analyses d'images. Ensuite, nous présentons les différentes méthodes de segmentation d'images publiées dans la littérature, et nous terminons avec une étude comparative des méthodes de segmentation afin de justifier le choix de celles qu'il faut adopter.

2.2. Analyse de l'image

Pour le traitement d'images, la segmentation ne peut être une partition aléatoire : elle est guidée par un but et elle doit répondre à des critères de qualité. L'analyse de l'image est une étape décisive sur laquelle va dépendre le résultat de la segmentation.

2.2.1. Analyse statistique

Les approches par modélisation statistique sont actuellement utilisées en analyse d'images. On peut trouver dans ce contexte, les modèles par champ de Markov [Bennett et Khotanzad 1998 ; Bouman et Shapiro 2003 ; Collet *et al.* 2003 ; Khotanzad et Hernandez 2003 ; Salzenstein *et al.* 2004]. On trouve aussi des méthodes qui se basent sur l'extraction des paramètres à partir d'histogrammes ou de matrices [Haddon et Boyce 1993 ; Schwartz et Pedrini 2007].

2.2.1.1. Modélisation Markovienne

Les champs de Markov sont des outils très utilisés en segmentation d'images [Daily 1989 ; Wesolkowski et Fieguth 2002 ; Hernandez et Khotanzad 2003 ; Lanchantin et Salzenstein 2005 ; Kato et Pong 2006 ; Schwartz et Pedrini 2007]. Leur intérêt est principalement de pouvoir modéliser des interactions entre les pixels à travers un modèle probabiliste [Moghrani 2007]. Considérons un champ X constitué de variables aléatoires X_s en chaque site $s \in S$ (s est le pixel, et S la grille de pixel). On désigne par X^s le champ privé de X_s , et V_s désigne le voisinage de s . Les lettres majuscules désignent les variables et champs aléatoires, les lettres minuscules les valeurs des réalisations respectives.

Un champ de Markov X est un champ aléatoire présentant la propriété suivante :

$$P(X_s = x_s / X^s = \mathbf{x}^s) = p(X_s = x_s / x_t, t \in V_s) \quad (2.1)$$

Ceci signifie que la probabilité en un site s conditionnellement au reste du champ est égale à la probabilité en ce site connaissant uniquement ses voisins.

Si on ajoute la contrainte de positivité $P(X = x) > 0, \forall x$ le théorème de Hammersley-Clifford établit qu'un champ de Markov est aussi un champ de Gibbs associé au même système de voisinage. Sa loi peut alors s'écrire de la façon suivante :

$$P(X_s = x_s) = \frac{1}{Z} \exp(-U(x)) = \frac{1}{Z} \exp(-\sum_{c \in C} V_c(x)) \quad (2.2)$$

Où Z est une constante de normalisation appelée fonction de partition de Gibbs, et C l'ensemble des cliques associées au voisinage V , c'est-à-dire regroupant tous les singletons et ensembles de tous les sites voisins.

Grâce à cette modélisation contextuelle, les champs de Markov peuvent aussi servir pour la modélisation des images. La figure 2.1 présente deux types de voisinages : le voisinage d'ordre un d'un pixel contient ses voisins en 4-connexité et celui d'ordre 2 contient ses voisins en 8-connexité.



Figure 2.1. Système de voisinage

2.2.1.2. Analyse par extraction des paramètres

Ces techniques se basent sur l'extraction des paramètres [Haddon et Boyce 1993 ; Schwartz et Pedrini 2007, Moghrani 2002], tels que les paramètres de la matrice de cooccurrence, les paramètres des histogrammes locaux, ainsi que les paramètres de matrice de longueurs de plage. Ces approches donnent de bons résultats pour des images mono-

composantes, mais leur application aux images multispectrales paraît irréalisable [Moghrani 2007].

En effet, une matrice de cooccurrence est une matrice de dimension $N * N$ où N est le nombre de niveaux de gris de l'image. Pour adapter cette méthode aux images multispectrales, il faut soit travailler bande par bande de façon scalaire, et dans ce cas l'information inter-bandes est perdue, soit travailler sur le cube image. Mais ce dernier cas est pratiquement impossible à traiter, car il impliquerait de travailler sur des matrices gigantesques de taille $NqNb * NqNb$, où Nq est le nombre de niveaux de gris, et Nb le nombre de bandes.

2.2.2. Analyse par transformation

Ces techniques d'analyse sont basées sur la transformation de l'image. Parmi les techniques les plus utilisées, on peut citer la transformée de Fourier, filtrage par un banc de filtres de Gabor [Jain et Farrokhinia 1991 ; Livens et Scheunders 1997 ; Zhang *et al.* 2002]. Ces approches sont basées sur l'analyse fréquentielle, elles sont largement utilisées dans la caractérisation de la texture dans les images en niveaux de gris. Ces méthodes donnent une représentation spectrale de l'image, c'est-à-dire une bijection entre l'espace spatial et son espace fréquentiel [Voisine 2002].

2.2.3. Analyse par fractals

Ces techniques d'analyse permettent d'estimer des propriétés sur la surface de l'image. Une droite a une dimension de un et une surface a une dimension de deux. Il existe des objets ayant des dimensions fractionnaires, que l'on appelle fractal [Voisine 2002].

2.2.4. Analyse en composantes principales « ACP »

Cette technique est basée sur la réduction de l'espace des attributs. Elle calcule dans un premier temps la matrice de corrélation T des N_a attributs. Dans un second temps, elle recherche

les valeurs propres λ_i et les vecteurs propres v_i de T . Pour finir elle sélectionne parmi les N attributs les N_{ACP} qui ont la plus grande valeur propre [Liu 1991, Voisine 2002].

2.2.5. Analyse de l'homogénéité

L'analyse d'homogénéité est très utilisée en segmentation d'images [Heng-Da et Ying 2000; Jing *et al.* 2003 ; Wang et Suter 2003]. L'homogénéité est apparentée à l'information locale extraite d'une image et reflète le degré d'uniformité d'une région donnée [Heng-Da et Ying 2000]. L'homogénéité joue un rôle important dans la segmentation d'images du moment que le résultat de la segmentation seraient plusieurs régions homogènes.

2.3. Segmentation

L'objectif de la segmentation est de partitionner l'image en entités définissant les objets constituant la scène. C'est une étape fondamentale qui conditionne le bon déroulement des étapes ultérieures.

La segmentation d'une image I consiste à la partitionner en un ensemble E_R de régions R_i . Les régions obtenues doivent être connexes, homogènes disposant de caractéristiques communes. La définition mathématique de la segmentation est donnée par les relations suivantes [Voisine 2002] :

$$\begin{aligned}
 - E_R &= \{R_1, R_2, \dots, R_n\} \\
 - \forall i R_i &\neq 0 \\
 - I &= \bigcup_i R_i \\
 - \forall i, j \ i \neq j \ R_i \cap R_j &= \phi
 \end{aligned}
 \tag{2.3}$$

2.4. Stratégies de segmentation

En traitement d'images, on distingue les traitements de haut-niveau, qui s'intéressent au contenu symbolique de l'image, et les traitements de bas-niveau, qui opèrent à l'échelle du pixel. Les traitements de bas-niveau, tels que le filtrage ou la segmentation, peuvent être très différents selon que l'image est mono-composante ou multi-composante.

Pour traiter les images multi-composantes, trois stratégies peuvent être adoptées [Ouattara 2009] : il s'agit des stratégies scalaires, marginales et vectorielles. Les deux premières stratégies ne prennent pas en compte l'aspect vectoriel de l'image multi-composante. En particulier, elles ignorent les corrélations qui peuvent exister entre les différentes composantes. Nous présentons dans ce qui suit les différentes stratégies qu'il est possible d'adopter pour traiter les images multispectrales.

2.4.1. Les stratégies scalaires

L'approche scalaire commence par une fusion des n composantes de l'image multicomposante. L'image sous forme mono-composante ainsi obtenue est traitée par la suite (figure 2.2). Par exemple, une image vectorielle couleur codée dans l'espace RVB peut être transformée, avant traitement, en une image scalaire. Cela peut être réalisé au moyen d'une analyse en composantes principales dont on ne retient que la première composante.

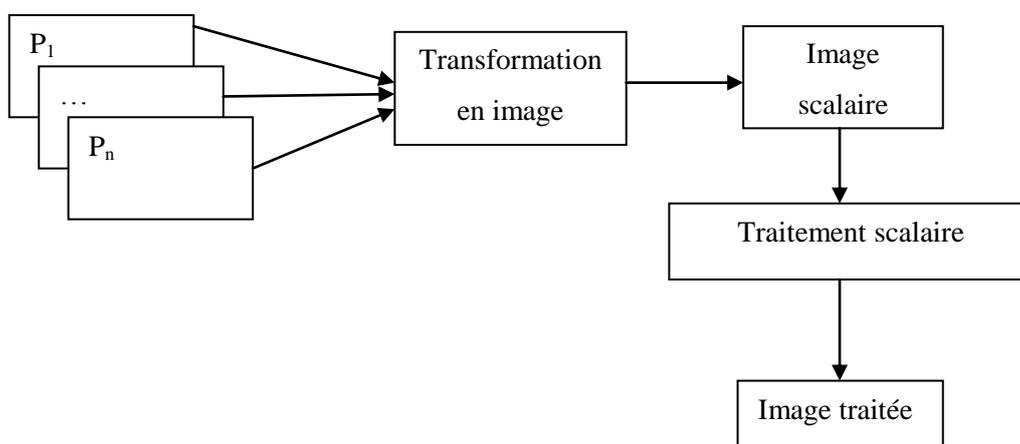


Figure 2.2. Stratégie scalaire

2.4.2. Les stratégies marginales

L'approche marginale opère un traitement scalaire sur chaque composante de l'image. Les résultats obtenus sont ensuite fusionnés en une seule image mono-composante (Figure 2.3). Cette stratégie demande autant de traitements qu'il y a de composantes.

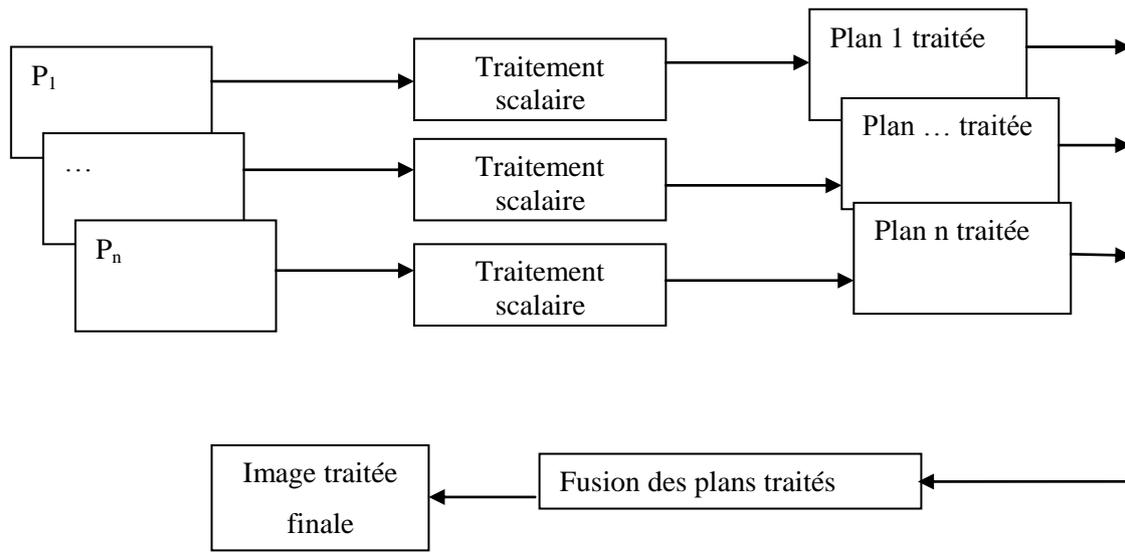


Figure 2.3. Stratégie marginale

2.4.3. Les stratégies vectorielles

L'approche vectorielle utilise directement, et de façon globale, l'information vectorielle présente dans l'image (figure 2.4). La corrélation entre composantes est ainsi prise en compte.

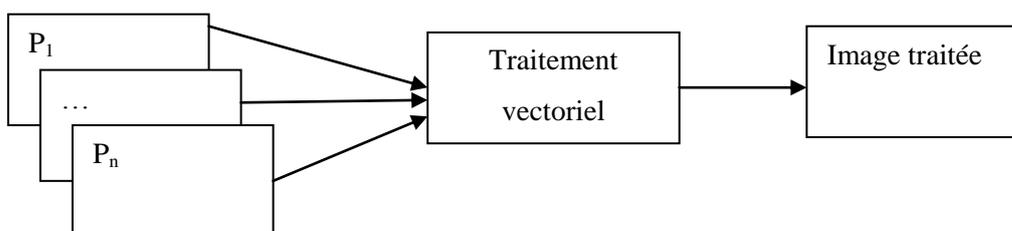


Figure 2. 4. Stratégie vectorielle

2.5. Méthodes de Segmentation

Il existe deux grandes approches de segmentation à savoir l'approche contour et l'approche région.

- l'approche contour est basée sur la détection des frontières qui forment les régions d'une image. Les méthodes peuvent soit modéliser le contour et essayer de rechercher dans l'image les pixels qui répondent à ce modèle; soit rechercher les points localisant une rupture de modèle de régions adjacentes.
- l'approche région consiste à déterminer directement les régions en regroupant les points qui ont les mêmes propriétés statistiques ou structurelles.

Cette section présente les deux grandes approches de la segmentation des images : l'approche contour et l'approche région.

2.5.1. Méthodes de détection de contour

Les méthodes de segmentation par détection de contours recherchent à localiser les transitions entre les régions. Elles utilisent la discontinuité dans une image pour détecter les bords et les contours des régions.

Les contours se manifestent dans l'image par une forte transition des valeurs de l'intensité (fort contraste).

Les méthodes de détection de contours reposent sur trois concepts : les techniques dérivatives et de filtrages, les approches morphologiques et les ruptures de modèles.

2.5.1.1. Les méthodes dérivatives et techniques de filtrages

Les méthodes dérivatives utilisent un opérateur de dérivation pouvant détecter la transition d'un signal [Fortier *et al.* 1999]. Le principe des méthodes dérivatives repose sur la détection d'une transition d'un signal à partir de sa dérivée. On peut citer, dans ce cas, les

opérateurs du premier ordre les plus courants : Prewitt et Sobel, Kirsch et Nagdif et les opérateurs du deuxième ordre, le Laplacien-gaussien. Dans le cas du filtrage, on peut citer le filtre de Canny et de Deriche.

2.5.1.2. Approche morphologique

Ces techniques peuvent être directement utilisées sur l'image [Géraud et Duret-Lutz 2003].

On considère l'image comme une surface dans un espace tridimensionnel $(i, j, I(i, j))$ [Voisine 2002].

Soit B un élément structurant (ex : une surface), on appelle :

✓ Dilatation: $D(i, j) = \text{Max}_{k,l \in B} [I(i-k, j-l) + B(k,l)]$

✓ Erosion : $E(i, j) = \text{Min}_{k,l \in B} [I(i-k, j-l) + B(k,l)]$

La détection du contour consiste à détecter les sauts :

✓ gradient par érosion : $\nabla_E I(i, j) = I(i, j) - E(i, j)$

✓ gradient par dilatation : $\nabla_D I(i, j) = D(i, j) - I(i, j)$

✓ laplacien morphologique: $L[I(i, j)] = \nabla_D I(i, j) - \nabla_E I(i, j)$

Ces méthodes utilisent les comparaisons entre valeurs et elles donnent des résultats comparables aux opérateurs de Prewitt et Sobel.

2.5.1.3. Rupture de modèle

L'approche par rupture de modèle consiste à représenter l'image par une fonction. On recherche explicitement un contour soit en le modélisant, soit en recherchant une rupture locale du modèle [Voisine 2002]. Pour les approches variationnelles [Chan *et al* 2000 ; Lee *et al.* 2005 ; Li *et al.* 2005 ; Martinez et Plat 2005 ; Rousson et Deriche 2005], les contours sont modélisés par des courbes élastiques à ajuster le mieux possible aux frontières des régions. Pour cela on associe une énergie dont la définition est étroitement liée à celle des contours. Les minimas locaux de cette énergie correspondent aux contours s'ajustant le mieux au modèle utilisé.

2.5.2. Méthodes de segmentation en régions

Les méthodes de l'approche région cherchent à différencier les régions en utilisant les propriétés de l'image telles que la couleur, texture, forme...etc. Ces méthodes utilisent principalement les critères de décision pour segmenter l'image en différentes régions selon la similarité des pixels. Nous proposons dans la suite les différentes méthodes de segmentation de type région.

2.5.2.1. Méthodes de segmentation par seuillage

La segmentation par seuillage est l'opération qui associe à chaque point de l'image une classe de luminance. Le seuillage est réalisé après comparaison des luminances à un ou plusieurs seuils. Le seuillage d'histogrammes est l'une des méthodes de segmentation les plus utilisées pour segmenter les images en niveau de gris. Ces techniques tentent de déterminer les classes de pixels par l'analyse des histogrammes monodimensionnels.

Dans le cas des images multispectrales, l'application des histogrammes nécessite la combinaison des vallées des différents histogrammes [Kurugollo *et al.* 2001; Cheng et Sun 2000].

Dans [Kurugollo *et al.* 2001], les auteurs proposent une méthode de segmentation d'images multi-bandes. Cette méthode est basée sur la segmentation de sous-ensembles de bandes, en utilisant le multi-seuillage, suivie par la fusion des résultats de la segmentation. Pour les images couleurs, les sous-ensembles de bandes sont choisis comme étant des paires RB, RV, BV pour lesquelles les histogrammes à deux dimensions sont traités via l'algorithme de multi-seuillage.

Dans une autre approche, Cheng et Sun [Cheng et Sun 2000] proposent une approche hiérarchique pour la segmentation des images couleur. Dans la première phase de la segmentation, les régions uniformes sont identifiées via le multi-seuillage sur l'histogramme de l'homogénéité. Dans le calcul de l'histogramme d'homogénéité, les informations globales et locales sont prises en compte. Dans la deuxième phase, on calcule l'histogramme de la teinte pour chaque région uniforme obtenue lors de la première phase. Après que la segmentation

hiérarchique est exécutée, un processus de fusion de régions est employé afin d'obtenir le résultat final de la segmentation.

2.5.2.2. Méthodes de classification

Ces méthodes consistent en un partitionnement de l'espace des attributs. Chaque partition correspond à une classe.

A– Classification bayésienne

Elle consiste à utiliser une information arbitraire sur les classes et sur l'appartenance d'un pixel à une classe [Murtagh *et al.* 2005]. Les observations faites sur l'image et les étiquettes sont des processus stochastiques.

- ✓ $C = \{c_s, s \in S\}$ processus des étiquettes, $c_s \in C$
 c_s est l'étiquette au site s qui prend ses valeurs dans C l'ensemble des classes.
- ✓ $x = \{x_s, s \in S\}$ processus d'observations.

Les méthodes bayésiennes consistent à estimer l'étiquette la plus vraisemblable c_s^* pour une observation donnée x . Parmi elles, on cite l'approche MAP et l'algorithme EM.

➤ *Maximum a posteriori (MAP)*

Le principe de la méthode MAP consiste à déterminer des étiquettes $c^* = (c_1, c_2, \dots, c_S)$ des pixels de l'image à partir de l'ensemble des niveaux de gris :

$$c^* = \arg \max_{c \in C} P(C=c/X=x) \quad (2.4)$$

$P(C=c/X=x)$ est la probabilité à postériori d'avoir $C=c$ sachant la réalisation $X=x$.

➤ **L'algorithme EM (Expectation Maximisation)**

L'algorithme EM est une technique générale pour l'estimation par maximum de vraisemblance. Cette technique permet d'estimer les paramètres lorsque les données observées sont incomplètes. Chaque itération de cet algorithme comporte deux étapes. L'étape d'espérance (E) et une étape de Maximisation (M) [Michaud 2005].

Soit Y , le vecteur aléatoire correspondant aux données observées y , ayant une fonction de densité dénotée $f(y/\theta)$, où $\theta = (\theta_1, \dots, \theta_d)^T$ est un vecteur de paramètres inconnus dans l'espace Θ . Soit $f(x/\theta)$, la fonction de densité du vecteur aléatoire X correspondant au vecteur de données complètes x . Alors la fonction de log-vraisemblance qui pourrait être formée pour θ si x était complètement observable est donnée par :

$$L(\theta/x) = \ln(f(x/\theta)) \quad (2.5)$$

Soit $\theta^{(0)}$, une valeur initiale de θ choisie arbitrairement, à laquelle l'algorithme débute. Alors, à la première itération, l'étape E (Espérance) de l'algorithme EM se calcule comme suit:

$$Q(\theta/\theta^{(0)}) = E_{\theta^{(0)}}[L(\theta/x)/y] \quad (2.6)$$

Ensuite l'étape M (Maximisation) maximise l'équation précédente par rapport à $\theta \in \Theta$. $\theta^{(1)}$ est choisi selon l'inéquation :

$$Q(\theta^{(1)}/\theta^{(0)}) \geq Q(\theta/\theta^{(0)}) \quad \theta \in \Theta. \quad (2.7)$$

1. Etape E : Calculer $Q(\theta/\theta^{(b)})$, où $Q(\theta/\theta^{(b)}) = E_{\theta^{(b)}}[L(\theta/x)/y]$
2. Etape M : Choisir $\theta^{(b+1)}$ qui une valeur de $\theta \in \Theta$ qui maximise l'équation précédente, c'est-à-dire telle que $Q(\theta^{(b+1)}/\theta^{(b)}) \geq Q(\theta/\theta^{(b)})$ pour tout $\theta \in \Theta$.

Ces deux étapes sont répétées jusqu'à ce que la différence entre la fonction de vraisemblance de l'itération (b+1) et celle de l'itération (b) ne change pratiquement plus.

$$L(\theta^{(b+1)}/y) - L(\theta^{(b)}/y) \leq \varepsilon$$

Où ε est une valeur arbitraire positive très près de zéro.

B – Méthodes de partitionnement

La classification par partitionnement s'agit d'un processus itératif, chargé de partitionner l'ensemble des pixels de l'image N en C classes. Dans le processus de classification, les éléments sont affectés à la classe la plus proche. Les représentants des classes sont régulièrement mis à jour, selon un critère de minimisation. Les méthodes de classification par partitionnement nécessitent trois pré-requis:

- ✓ Chaque objet (pixel) doit être représenté par un vecteur d'attributs ;
- ✓ Un critère pour classifier les objets dans les classes est fixé, une distance entre éléments est définie ;
- ✓ Un critère qui représente la stratégie de fusion ou de dissociation des classes est donné.

Parmi les méthodes par partitionnement les plus répandues on trouve:

- (1) La méthode des k-moyennes (kmeans).
- (2) L'algorithme des K plus proches voisins (KPP)

➤ **La méthode k-moyennes (Kmeans)**

La méthode prend comme représentant de chaque classe son centre de gravité [Theiler et Gisler 1997]. Les centres sont recalculés à chaque nouvelle affectation d'un élément à une classe [Moghrani 2007].

1. Choisir K individus distincts qu'on appelle noyaux des classes,

2. Construire k classes C_i telles que: $c_i = \{x/d(y_i, x) < d(y_j, x) \forall j \neq i\}$ (2.8)

3. Recalculer les centres des classes : $y_i = \frac{\sum_{x \in C_i} x}{|C_i|}$ (2.9)

4. Reconstruire les k nouvelles classes en retournant à l'étape 2. Si les nouvelles classes ne sont pas différentes des anciennes, s'arrêter.

➤ **L'algorithme des k les plus proches voisins(KPP)**

Consiste à attribuer l'objet représenté par un vecteur d'observation à la classe la plus représentée, parmi les k les plus proches voisins d'un objet [Nuzillard et Lazar 2007 ; Voisine 2002].

1. On affecte à N vecteurs d'un espace vectoriel une classe parmi N_C classes.

2. Pour tout vecteur a , on recherche parmi les $N - 1$ autres vecteurs les k plus proches voisins. On affecte au vecteur a la classe la plus représentée parmi les k vecteurs.

3. Tant que le système n'est pas stable on retourne en 2.

Pour éviter des erreurs, on utilise une classe de rejet C_{rej} . Si la boule centrée en a et de rayon r ne contient pas au moins K' voisins alors a a pour classe C_{rej} .

2.5.2.3. Approches par classification floue

Dès l'introduction du concept d'ensemble flou par Zadeh [Zadeh 1965], on s'est aperçu que la notion de classe utilisée en reconnaissance de formes ou en segmentation d'images, trouvait là un cadre naturel d'expression.

En effet, une classe est un groupe d'individus présentant des similitudes communes. D'une part, les similitudes sont plus ou moins fortes entre les individus d'une même classe. D'autre part, un même individu peut présenter des similitudes avec des individus d'autres classes. Le degré d'appartenance d'un individu n'est pas localisé à une classe déterminée mais se trouve distribuée sur plusieurs classes. Nous retrouvons là le concept même d'ensemble flou, puisque, dans ce formalisme, un élément peut appartenir plus ou moins fortement à plusieurs ensembles flous. Les ensembles flous semblent constituer le cadre de représentation naturel de la notion de classe.

Les algorithmes de classification classiques considèrent implicitement les classes comme nettes. Il est à constater, que les méthodes de discrimination bayésiennes donnent pour un échantillon à reconnaître une probabilité d'appartenir à chaque classe. Cependant, la notion de probabilité est fondamentalement différente de la notion d'appartenance graduée d'un élément à un ensemble.

Parmi les méthodes de classification floues, l'algorithme fuzzy C-means (FCM) est le plus utilisé dans la segmentation d'images [Bezdek 1981]. Durant les itérations, le degré d'appartenance flou u_{ij} est mis à jour comme une fonction de distance par rapport aux classes.

Plusieurs approches floues ont été dérivées à partir de l'algorithme FCM [Pham 1999 ; Noordam *et al.* 2000; Chen et Zhang 2004 ; Cai *et al.* 2007 ; Feng et Licheng 2011].

Dans [Noordam *et al.* 2000], les auteurs présentent une technique semi-supervisée basée sur l'algorithme FCM. La technique GG-FCM est utilisée pour incorporer l'information spatiale durant le processus de la classification floue.

Dans [Chen et Zhang 2004], Chen et Zhang ont modifié la fonction objective de l'algorithme FCM en introduisant un terme spatial, où l'étiquetage du pixel considéré est

influencé par les labels des pixels du voisinage. Les auteurs ont présenté deux variantes FCM_S1 et FCM_S2, où deux types de filtrage ont été utilisés.

2.5.2.4. Méthodes de segmentation par croissance de régions

Cette technique est ascendante et part du pixel pour remonter jusqu'aux régions en agrégeant les pixels selon un critère d'homogénéité [Ikonomakis *et al.* 2000]. On appelle ϕ la fonction qui caractérise une propriété d'une région R_i et S_n l'ensemble des pixels non attribués à une région au début de l'étape n .

L'algorithme général de croissance de régions consiste à [Voisine 2002]:

1. Définir les germes des régions g_i . Les germes sont des pixels ou des groupes de pixels qui serviront de base pour agréger les pixels dits " libres " qui ne sont pas affectés à une région. Le choix des germes influence la qualité de la segmentation, plus le germe est un bon représentant d'une région plus l'agrégation obtenue représentera une région homogène;
2. tant que $S_n \neq 0$, on affecte le pixel élément de S_n au germe g_i qui minimise une fonction W . Cette fonction est la somme des fluctuations de la propriété ϕ des régions.

2.5.2.5. Méthodes de segmentation par divisions et fusion de régions

Le point commun de ces méthodes est qu'elles commencent avec une partition initiale non homogène de l'image (habituellement la partition initiale est l'image elle-même). Elles continuent la division jusqu'à ce que des partitions homogènes soient obtenues [Tremeau et Colontini 2000].

Après la phase de division, il reste souvent plusieurs petits fragments de régions qui ont à être connectées. La phase de fusion accomplit cela, en associant les régions voisines. En se basant sur les conditions d'homogénéité, la fusion de régions continue jusqu'à ce qu'un maximum de segments connectés soit obtenu.

Le graphe d'adjacence de régions (RAG) est une structure communément adoptée dans la phase de fusion [Saarinen 1994 ; Colantini et Laget 2000 ; Tremeau et Colontini 2000]. L'un des avantages des graphes d'adjacence de régions est qu'ils fournissent une vue spatiale de l'image.

Une manière de représenter le graphe d'adjacence consiste à associer un nœud à chaque région, et une arrête à chaque paire de régions adjacentes. Le graphe d'adjacence des régions est utilisé pour fusionner les régions adjacentes qui présentent des distributions spectrales suffisamment proches.

2.6. Comparaison des méthodes de segmentation

Les méthodes de détection de contours donnent de bons résultats quand les contours de l'image sont bien définis. Cependant, dans le cas des images bruitées ou faiblement contrastées, les méthodes contours nécessitent une étape supplémentaire afin de fermer les bords des régions.

Les méthodes de segmentation par seuillage d'histogrammes permettent d'obtenir des régions homogènes. Cependant, les régions obtenues ne sont pas compactes. En plus, l'extension de l'histogramme vers l'espace multispectral est difficile à réaliser.

Les méthodes de classification bayésiennes nécessitent des connaissances à priori. En plus, ces méthodes présentent l'inconvénient d'imposer un modèle sur la répartition des observations et des étiquettes.

Les méthodes de classification par partition sont efficaces pour partitionner un ensemble de points par apprentissage ou non. Ces méthodes donnent de bons résultats quand les régions sont uniformes. Cependant, elles donnent de mauvais résultats quand les images à traiter sont bruitées. En effet, les méthodes de classification par partition travaillent dans un certain espace d'attributs, et négligent le rapport spatial entre les pixels de l'image.

Par rapport aux méthodes de classification classiques, les méthodes de classification floues présentent des caractéristiques plus robustes. En effet, ces méthodes peuvent retenir plus d'informations que les autres méthodes de classification.

Dans les méthodes par croissance de régions et les méthodes par division et fusion des régions, les pixels sont classés exclusivement sur la base de leur relation spatiale. Dans le résultat de la segmentation, on obtient des régions spatialement connectées. Cependant, rien ne garantit que ces régions soient homogènes dans un certain espace de caractéristiques. En plus, l'inconvénient majeur des méthodes de croissance des régions est la sélection des pixels germes qui doit se faire soigneusement.

Des travaux récents ont montré que la segmentation d'images est améliorée quand l'information spectrale et spatiale est considérée [Yamazaki and Gingras 1995; Pedrycz and Waletzky 1997; Theiler and Gisler 1997; Noordam *et al.* 2000; Ameer *et al.* 2004; Makrogiannis *et al.* 2005; Chuang *et al.* 2006 ; Gruia *et al.* 2007; Yong *et al.* 2008 ; Krinidis et Chatzis 2010].

Dans [Yamazaki et Gingras 1995], une méthode de segmentation des images texturées combinant l'information spectrale et spatiale a été proposée. Dans cette approche, les images sont modélisées avec un champ de Markov. Les centres de classes sont estimés en utilisant une classification bayésienne basée sur l'estimation du maximum à posteriori MAP.

Dans [Chuang *et al.* 2006], les auteurs présentent un algorithme de segmentation (SFCM) basée sur la classification spectrale et spatiale des pixels de l'image. Dans cet algorithme, l'information spatiale est incorporée dans la fonction d'appartenance de l'algorithme FCM. La fonction spatiale est la somme des fonctions d'appartenance des pixels appartenant au voisinage du pixel considéré.

Dans [Krinidis et Chatzis 2010], Krinidis et Chatzis présentent une variante de l'algorithme de classification FCM. L'algorithme proposé (FLICM) incorpore l'information spectrale et spatiale dans la fonction objective de l'algorithme FCM.

2.7. Application à la segmentation d'images couleur texturées

Dans les paragraphes précédents, nous avons montré, que l'incorporation de l'information spectrale et spatiale améliore les résultats de la segmentation. Nous avons montré également que les approches de classification floues présentent des caractéristiques robustes par rapport aux autres méthodes de segmentation.

Afin de montrer l'efficacité de la segmentation spectrale-spatiale floue, nous avons retenu deux approches de segmentation SFCM et FLICM. Ces deux approches ont été évaluées en appliquant celles-ci sur des images synthétiques couleur texturées. Ces images ont été obtenues à partir de la base de données d'images de texture de couleur du site Web (Colombia database). Les images synthétiques sont données par les figures 2.5 et 2.6.

L'image synthétique donnée par la figure 2.5 se compose de 256 x 256 pixels recueillis dans quatre carrés de même taille. Cette image est constituée de quatre sortes de textures couleur fines.

L'image synthétique donnée par la figure 2.6 se compose de 256×256 Pixels rassemblés dans quatre carrés de même taille. Elle est constituée de trois sortes de textures couleur grossières.

Les performances des deux algorithmes sont comparées en utilisant le taux de bonne segmentation (SA). Ce critère est défini comme la somme des pixels correctement classifiés divisés par la somme de tout le nombre de Pixels [Ahmed *et al.* 2002].

$$SA = \frac{\sum_{i=1}^C A_i \cap C_i}{\sum_{j=1}^C C_j} \quad (2.10)$$

Où :

C est le nombre de classes,

A_i représente l'ensemble de pixels appartenant à la $i^{\text{ème}}$ classe trouvés par l'algorithme, tandis que C_i représente l'ensemble de pixels appartenant à la $i^{\text{ème}}$ classe dans l'image vérité terrain.

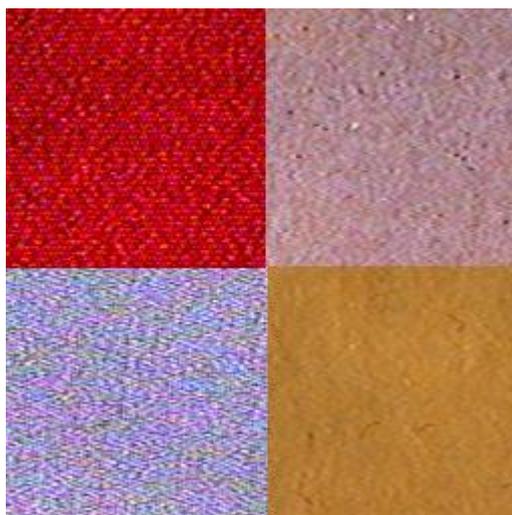


Figure 2.5. Image synthétique composée de quatre textures couleur.

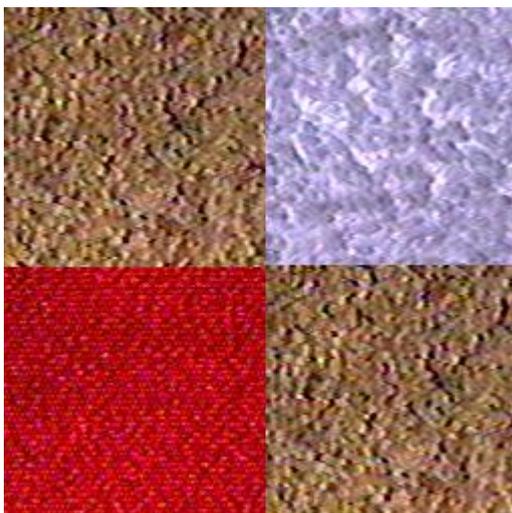


Figure 2.6. Image synthétique composée de trois textures couleur.

Nous décrivons, ci après, les approches de segmentation utilisés et les résultats obtenus pour chaque méthode. Avant de développer les algorithmes de segmentation SFCM et FLICM, nous rappelons en premier l'algorithme de classification floue (FCM).

L'algorithme c-moyennes floues introduit par Dunn [Dunn 1974] et amélioré par Bezdek [Bezdek 1981] est une méthode itérative, basée sur la minimisation de la fonction objective suivante:

$$J = \sum_{j=1}^N \sum_{i=1}^C u_{ij}^m \|\mathbf{x}_j - \mathbf{v}_i\|^2 \quad (2.11)$$

Où u_{ij} représente le degré d'appartenance du pixel \mathbf{x}_j au centre de la $i^{\text{ème}}$ classe \mathbf{v}_i ,

\mathbf{x}_j est le vecteur d'attribut multidimensionnel du pixel,

\mathbf{v}_i est le centre multidimensionnel de la classe,

$\|\ \|\$ est une norme métrique mesurant la similarité entre le pixel \mathbf{x}_j et le centre \mathbf{v}_i ,

et m est un paramètre flou de la partition résultante.

L'algorithme de segmentation Floue FCM est donné par les étapes suivantes :

- 1) Supposer que $\mathbf{x}=(x_1, x_2, \dots, x_j, \dots, x_N)$ les pixels de l'image à partitionner. On choisit le nombre de classes, le paramètre flou m et la condition d'arrêt ξ .
- 2) Initialiser \mathbf{u} en utilisant une valeur aléatoirement choisie dans l'intervalle $[0,1]$.
- 3) Fixer le compteur de boucle $b = 0$
- 4) Calculer le centre de classe \mathbf{v}_i :

$$\mathbf{v}_i = \frac{\sum_{j=1}^N u_{ij}^m \cdot \mathbf{x}_j}{\sum_{j=1}^N u_{ij}^m} \quad (2.12)$$

- 5) Mettre à jour u_{ij} comme une fonction de distance aux centres de classes:

$$u_{ij} = \frac{1}{\sum_{l=1}^c \left(\frac{d_{ij}^2}{d_{lj}^2} \right)^{\frac{1}{m-1}}} \quad (2.13)$$

- 6) Si $\text{Max}\{\mathbf{u}(b) - \mathbf{u}(b+1)\} < \xi$ alors arrêt, sinon, mettre $b=b+1$ et aller à l'étape 4.

Segmentation par l'algorithme de classification spatiale floue SFCM

Dans l'approche de segmentation spatiale floue SFCM, l'information spatiale est incorporée dans la fonction d'appartenance de l'algorithme FCM. La fonction spatiale et la sommation des fonctions d'appartenance des pixels voisins.

La fonction spatiale est donnée par :

$$h_{ij} = \sum_{k \in NB(x_j)}^N u_{ik} \quad (2.14)$$

Où $NB(x_j)$ représente une fenêtre centrée sur le pixel central x_j dans le domaine spatial.

Une fenêtre 3x3 a été utilisée.

La fonction spatiale h_{ij} représente la probabilité que le pixel x_j appartienne à la i ème classe.

La fonction spatiale est incorporée à la fonction d'appartenance comme suit:

$$u'_{ij} = \frac{u_{ij}^p \cdot h_{ij}^q}{\sum_{k=1}^c u_{kj}^p \cdot h_{kj}^q} \quad (2.15)$$

Où (p, q) sont des paramètres pour contrôler le degré d'importance des deux fonctions.

A chaque itération, l'algorithme de classification utilise un processus à deux étapes. La première étape de l'approche SFCM est similaire à l'algorithme FCM, où on calcule la matrice d'appartenance \mathbf{u} dans le domaine spectral. Dans la deuxième étape, les coefficients d'appartenance de chaque pixel sont représentés dans le domaine spatial, et la fonction spatiale u'_{ij} est calculée. Enfin, l'algorithme FCM procède avec la nouvelle matrice d'appartenance où l'information spatiale a été incorporée.

L'algorithme SFCM comporte les étapes suivantes:

- (1) Choisir le nombre de classes, le paramètre flou m et la condition d'arrêt ξ .
- (2) Initialiser \mathbf{u} en utilisant une valeur aléatoirement choisie dans l'intervalle $[0,1]$.
- (3) Fixer le compteur de boucle $b=0$
- (4) Calculer les coefficients u_{ij} dans le domaine spectral en utilisant (2.13).
- (5) Calculer les coefficients u'_{ij} dans le domaine spatial en utilisant (2.15).
- (6) Calculer les centres de classes v_i en utilisant (2.12).
- (7) Si $\text{Max } v(b) - v(b+1) < \xi$ alors arrêt, sinon, mettre $b=b+1$ et aller à l'étape 4.

Segmentation par l'algorithme de classification locale floue FLICM

Dans l'algorithme de segmentation locale floue FLICM, l'information spatiale est incorporée dans la fonction objective de l'algorithme FCM. Elle est donnée par la relation suivante:

$$J_m = \sum_{i=1}^N \sum_{k=1}^c \left[u_{ki}^m \|x_i - v_k\|^2 + G_{ki} \right] \quad (2.16)$$

Le terme local flou G_{ki} est défini tel que :

$$G_{ki} = \sum_{\substack{j \in N_i \\ i \neq j}} \frac{1}{d_{ij} + 1} (1 - u_{kj})^m \|x_j - v_k\|^2 \quad (2.17)$$

Le terme G_{ki} est utilisé pour incorporer l'information spectrale et spatiale de chaque pixel de l'image,

où le pixel i est le centre de la fenêtre locale (par exemple une fenêtre 3x3),

k est un indice de référence pour les classes,

le pixel j appartient à l'ensemble des pixels voisins dans la fenêtre autour du pixel i (N_i),

d_{ij} est la distance Euclidienne entre les pixels i et j ,

u_{kj} est le degré d'appartenance du pixel j à la classe k ,

et v_k est le prototype du centre de la classe k .

Les degrés d'appartenance flous u_{ki} et les centres de classes v_k qui minimisent J_m sont obtenus par les relations suivantes:

$$u_{ki} = \frac{1}{\sum_{j=1}^c \left(\frac{\|x_i - v_k\|^2 + G_{ki}}{\|x_i - v_j\|^2 + G_{ji}} \right)^{\frac{1}{m-1}}} \quad (2.18)$$

$$v_k = \frac{\sum_{i=1}^N u_{ki}^m x_i}{\sum_{i=1}^N u_{ki}^m} \quad (2.19)$$

L'algorithme FLICM est donné par les étapes suivantes :

- (1) Choisir le nombre de classes c , le paramètre flou m et la condition d'arrêt ξ .
- (2) Initialiser \mathbf{u} en utilisant une valeur aléatoirement choisie dans l'intervalle $[0,1]$.
- (3) Fixer le compteur de boucle $b=0$
- (4) Calculer les centres de classes en utilisant (2.19).
- (5) Calculer les coefficients u_{ij} en utilisant (2.18).
- (6) Si $\text{Max}\{\mathbf{u}(b)-\mathbf{u}(b+1)\} < \xi$ alors arrêt, sinon, mettre $b=b+1$ et aller à l'étape 4.

La segmentation de l'image synthétique couleur de la figure 2.5 par les algorithmes FCM, SFCM, et FLICM rapporte les images des figures 2.7, 2.8 et 2.9, respectivement.

La segmentation de l'image synthétique couleur de la figure 2.6 par les algorithmes FCM, SFCM, et FLICM rapporte les images des figures 2.10, 2.11 et 2.12, respectivement.

Pour l'algorithme FCM, les résultats montrent que les classes sont fragmentées dans le domaine spatial. Les contours des régions ne sont pas clairement délimités. Pour les images synthétiques des figures 2.5 et 2.6, l'algorithme FCM rapporte des taux de segmentation de 87,59% et 87,36% respectivement.

Les algorithmes SFCM et FLICM, rapportent des cartes de segmentation compactes et cohérentes, avec une reproduction satisfaisante des contours des images. La table 2.1 donne les

taux de segmentation comparatifs de l'image de la figure 2.5. La table 2.2 donne les taux de segmentation comparatifs de l'image de la figure 2.6.

Pour les images des figures 2.5 et 2.6, l'algorithme FLICM rapporte des taux de segmentation optimaux de 97,66% et 97,35% respectivement. Pour l'image de la figure 2.5 l'apport des algorithmes SFCM et FLICM par rapport à l'algorithme FCM est de 6,73% et 10,07%, respectivement. Pour l'image de la figure 2.6 l'apport des algorithmes SFCM et FLICM par rapport à l'algorithme FCM est de 6,8% et 9,99%, respectivement. Ces résultats montrent que l'incorporation de l'information spectrale et spatiale améliore considérablement le résultat de la segmentation.

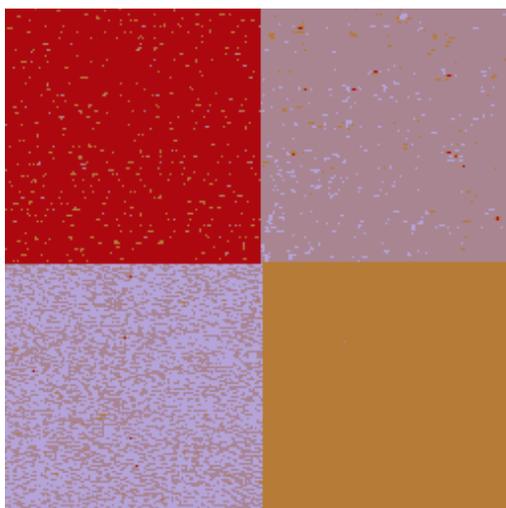


Figure 2.7. Résultat de la segmentation de l'image synthétique de la figure 2.5 en utilisant l'algorithme FCM (SA= 87,59%)

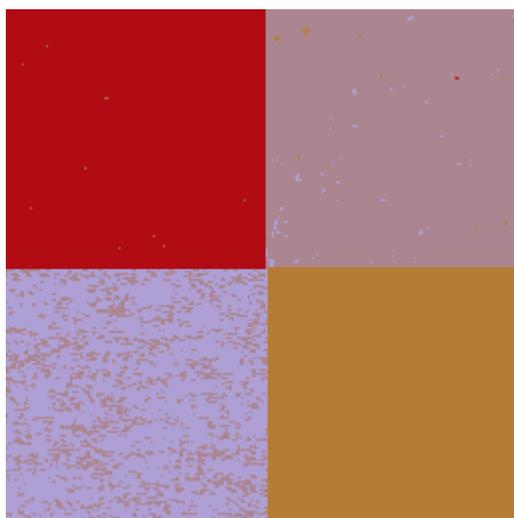


Figure 2.8. Résultat de la segmentation de l'image synthétique de la figure 2.5 en utilisant l'algorithme SFCM (SA= 94,32%)

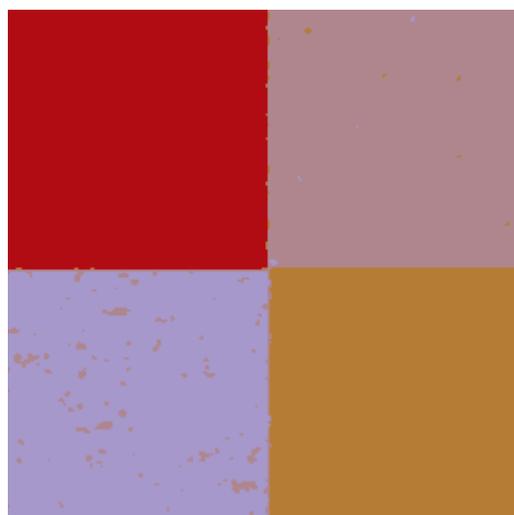


Figure 2.9. Résultat de la segmentation de l'image synthétique de la figure 2.5 en utilisant l'algorithme FLICM (SA= 97,66%)

Table 2.1. Taux de segmentation (SA) pour les différentes approches

Approches	Taux de segmentation SA (%)
FCM	87,59%
SFCM	94,32%
FLICM	97,66%

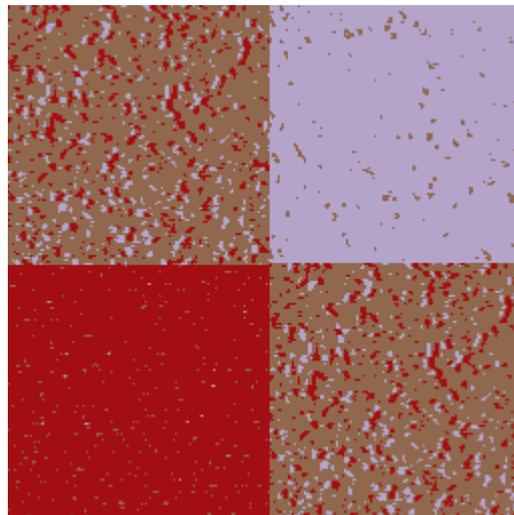


Figure 2.10. Résultat de la segmentation de l'image synthétique de la figure 2.6 en utilisant l'algorithme FCM (SA= 87,36%)

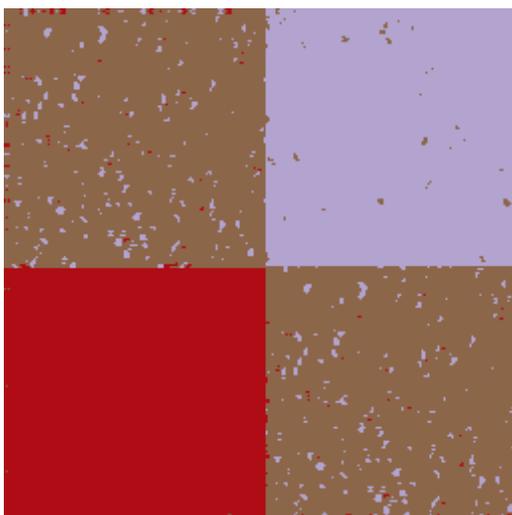


Figure 2.11. Résultat de la segmentation de l'image synthétique de la figure 2.6 en utilisant l'algorithme SFCM (SA=94,16%)

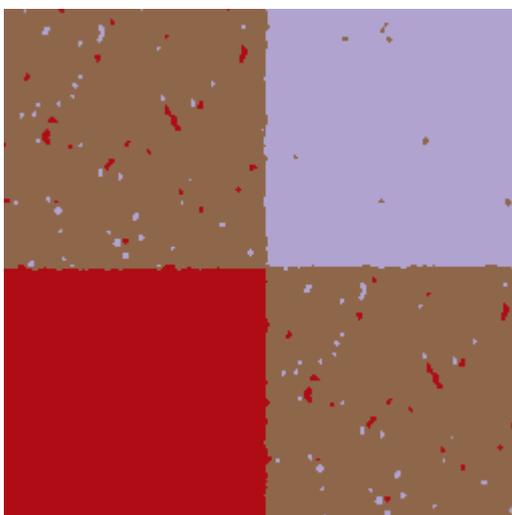


Figure 2.12. Résultat des la segmentation de l'image synthétique de la figure 2.6 en utilisant l'algorithme FLICM (SA=97,35%)

Table 2.2. Taux de segmentation (SA) pour les différentes approches

Approches	Taux de segmentation SA (%)
FCM	87,36%
SFCM	94,16%
FLICM	97,35%

2.8. Discussion

Dans ce chapitre, nous avons passé en revue les différentes approches de segmentation d'images existantes dans la littérature. Après une étude comparative des différentes méthodes, nous avons opté pour des approches de segmentation combinant l'information spectrale et spatiale de l'image.

Afin d'évaluer ces approches, deux méthodes de segmentation (SFCM et FLICM) ont été retenues. Ces approches sont basées sur la combinaison de l'information spectrale et spatiale floues de l'image. Les deux approches rapportent des cartes de segmentation compactes et cohérentes, la reproduction des contours est satisfaisante. La contribution des deux méthodes par rapport à l'algorithme FCM est de 6,765% et 10,03% respectivement. Les résultats montrent que la combinaison de l'information spectrale et spatiale améliore considérablement le résultat de la segmentation.

En tenant compte des résultats obtenus, nous avons mis au point deux nouvelles approches de segmentations d'images. La première méthode utilise une segmentation récursive locale-spectrale floue, qui réduit dynamiquement le nombre de classes. La deuxième approche est basée sur la classification floue des textures spectrales et l'analyse d'homogénéité locale. Le but de ces deux méthodes est la détection des nuages dans les images satellitaire multipectrales MSG. Les approches proposées seront décrites dans les chapitres trois et quatre.

CHAPITRE 3

SEGMENTATION LOCALE–SPECTRALE FLOUE

3.1. Problématique

La segmentation est une étape primordiale en traitement d'images. En effet, celle-ci conditionne la qualité de l'interprétation puis la prise de décision effectuée sur l'image ultérieurement. Le but principal de la segmentation est de partitionner l'image en régions homogènes. Plusieurs techniques de segmentation d'images multispectrales ont été récemment développées [Devaux et al. 2000 ; Collet *et al.* 2003 ; Liang *et al.* 2003 ; Mitra *et al.* 2003 ; Martinez et al. 2005 ; Dou 2006]. Ces techniques sont utilisées dans plusieurs domaines de recherche tels que la biologie, la chimie, la médecine, la télédétection etc.

La segmentation d'images reste un problème loin d'être résolu. En effet, avec les progrès technologiques des capteurs, un nombre énorme d'images avec une résolution spectrale et spatiale élevée, sont produites chaque jour. Par conséquent, il est nécessaire d'élaborer de nouvelles méthodes de segmentation qui permettent de détecter les régions d'intérêt dans les images multispectrales.

Dans l'analyse des images météorologiques, la détection des nuages est une opération importante dans le traitement des données météorologiques. Le problème de détection des

différents types de nuages, peut être résolu par l'analyse des images multispectrales, telles que les images satellitaires MSG.

Dans ce chapitre, nous présentons une nouvelle méthode de segmentation d'images multispectrales. Le but de la méthode est la détection des nuages dans les images satellitaires multispectrales MSG. L'approche proposée utilise une segmentation récursive, qui réduit dynamiquement le nombre de classes. Cet algorithme et les résultats obtenus seront présentés dans les prochaines sections.

3.2. Description de la méthode

Cette section détaille la méthode de segmentation mise au point pour détecter les nuages dans les images Meteosat Seconde Génération [Bitam and Ameur 2013]. L'approche emploie une segmentation récursive Locale-Spectrale Floue (LSF) qui réduit dynamiquement le nombre de classes. A chaque itération, la segmentation est effectuée en deux étapes. Dans la première étape, une segmentation initiale de l'image est obtenue en utilisant une classification locale floue. L'algorithme de classification est formulé en modifiant la mesure de similarité de l'algorithme c-moyennes floue (FCM). La nouvelle fonction de similarité inclue l'information spectrale aussi bien que l'homogénéité et l'information de classification spatiale de chaque pixel considéré. Dans la deuxième étape, un processus de fusion de régions hiérarchique est utilisé pour réduire le nombre de classes. L'algorithme de segmentation procède avec la nouvelle partition jusqu'à obtenir le résultat final de la segmentation.

3.2.1. Algorithme de classification local flou

Cet algorithme est formulé en modifiant la mesure de similarité de l'algorithme c-moyennes flou (FCM). La nouvelle fonction de similarité inclut l'information spectrale, l'homogénéité et l'information de classification spatiale de chaque pixel considéré.

Dans cette section, nous rappelons d'abord l'algorithme FCM dont le principe a été employé dans l'approche proposée. Ensuite, nous présentons la nouvelle mesure de similarité spectrale-locale floue (SL) FCM.

3.2.1.1. Classification C-moyennes Floue (FCM)

La classification floue signifie que chaque pixel n'est pas associé à une classe unique, mais à un vecteur de probabilités d'appartenance aux différentes classes. Pour chaque classe i un réel p_{xi} est associé. Cette valeur représente la probabilité d'appartenance du pixel x à la classe i . Le nombre de classes est noté C .

Deux relations doivent être vérifiées:

$$0 \leq p_{xi} \leq 1 \quad (3.1)$$

$$\sum_{i=1}^C p_{xi} = 1 \quad \forall x \quad (3.2)$$

La classification floue permet de passer de la représentation spectrale des pixels à leurs appartenances aux classes présentes dans l'image. Ce changement de représentation permet de modifier la notion de distance entre les pixels de l'image.

Comparé aux méthodes de classification classiques, l'algorithme FCM permet de retenir plus d'informations de l'image originale. Plusieurs techniques de segmentation basées sur l'algorithme FCM ont été récemment développées. Ces techniques sont utilisées dans de nombreux domaines de recherche tels que l'imagerie médicale et satellitaire [Thitimajshima 2000 ; Dou 2006 ; Gruia et Cristea 2007 ; Huynh et Jong-Myon 2009 ; Podenok et Sadykhov 2008 ; Dong-Chul 2010 ; Kannan *et al.* 2010].

➤ L'algorithme FCM

L'algorithme C moyennes floues FCM introduit par Bezdek [Bezdek 1981], est une méthode itérative qui recherche C groupes compacts dans un nuage de points multidimensionnel de taille N . Il associe à chaque élément x_j d'un ensemble de descripteurs p -dimensionnels $X = \{x_j, 1 \leq j \leq N, x_j \in R^p\}$, une partition floue U telle que :

$U=(u_{ij}), 1 \leq i \leq C, 1 \leq j \leq N$, dont les éléments u_{ij} , dans $[0, 1]$, sont les degrés d'appartenance de x_j à la classe i .

L'algorithme FCM est basé sur la minimisation de la variance totale intra-classes:

$$J = \sum_{j=1}^N \sum_{i=1}^C u_{ij}^m \|x_j - v_i\|^2 \quad (3.3)$$

Sous les contraintes:

$$(\forall i \in \{1 \dots C\}) \sum_{j=1}^N u_{ij} < N \quad \text{et} \quad (3.4)$$

$$(\forall j \in \{1 \dots N\}) \sum_{i=1}^C u_{ij} = 1$$

Où u_{ij} représente le degré d'appartenance du pixel x_j au centre de la $i^{\text{ème}}$ classe v_i ,

x_j est le vecteur d'attribut multidimensionnel du pixel,

v_i est le centre multidimensionnel de la classe,

$\| \cdot \|$ est une norme métrique mesurant la similarité entre le pixel x_j et le centre v_i ,

et m est un paramètre flou de la partition résultante.

La distance entre deux pixels x_i et x_j est généralement définie par la distance euclidienne $\Phi_{\text{eucl}}(x_i, x_j)$ dans leur espace des données.

La mesure euclidienne est un cas particulier de la distance de Minkowski avec $p=2$. Elle est donnée par la relation suivante:

$$\Phi_{\text{min kovski}}(x_i, x_j) = \left(\sum_{l=1}^d |x_{il} - x_{jl}|^p \right)^{\frac{1}{p}} \quad (3.5)$$

Où $x_i = \{x_{i1}, \dots, x_{id}\}$

Durant l'optimisation itérative de J , la matrice d'appartenance \mathbf{u} , formée des éléments u_{ij} , et les centres de classes sont mis à jour comme suit :

1. Supposer que $\mathbf{x}=(x_1, x_2, \dots, x_j, \dots, x_N)$ les pixels de l'image à partitionner. On choisit le nombre de classes, le paramètre flou m et la condition d'arrêt ξ .
2. Initialiser \mathbf{u} en utilisant une valeur aléatoirement choisie dans l'intervalle $[0,1]$.
3. Fixer le compteur de boucle $b = 0$
4. Calculer le centre de classe \mathbf{v}_i :

$$\mathbf{v}_i = \frac{\sum_{j=1}^N u_{ij}^m \cdot \mathbf{x}_j}{\sum_{j=1}^N u_{ij}^m} \quad (3.6)$$

5. Mettre à jour u_{ij} comme une fonction de distance aux centres de classes :

$$u_{ij} = \frac{1}{\sum_{l=1}^c \left(\frac{d_{ij}^2}{d_{lj}^2} \right)^{\frac{1}{m-1}}} \quad (3.7)$$

6. Si $\text{Max}\{\mathbf{u}(b) - \mathbf{u}(b+1)\} < \xi$ alors arrêt, sinon, mettre $b=b+1$ et aller à l'étape 4.

3.2.1.2. Mesure de similarité Spectrale-locale (SL) FCM

Une des caractéristiques de l'image, est que les pixels voisins sont fortement corrélés. En d'autres termes, les pixels voisins peuvent avoir des caractéristiques similaires, et la probabilité qu'ils appartiennent à la même classe est très grande. Dans les images multispectrales, l'information locale d'un pixel donné se compose de l'information spectrale et spatiale. Ce rapport local est important dans la classification des images mutispectrales. Afin de déterminer le degré de similarité entre les pixels de l'image, l'algorithme FCM utilise une mesure de similarité dans l'espace multidimensionnel. Cette métrique, utilise l'information spectrale dans l'espace des attributs, et ne tient pas compte de l'information spatiale des pixels de l'image.

Afin d'incorporer l'information locale dans la mesure de similarité, deux formes peuvent être utilisées :

$$\text{Forme d'addition:} \quad \varphi'(x_i, y_j) = \varphi'(x_i, y_j) + w(x_i, \partial_i, y_j) \quad (3.8)$$

$$\text{Forme de multiplication:} \quad \varphi'(x_i, y_j) = w(x_i, \partial_i, y_j) \times \varphi'(x_i, y_j) \quad (3.9)$$

Où la fonction $\varphi'(x_i, y_j)$ est la mesure de similarité dans le domaine spectral-spatial de l'image, et $w(x_i, \partial_i, y_j)$ est une fonction locale qui permet d'incorporer l'information sur le contexte local de l'image.

L'un des schémas d'arrangement des pixels voisins ∂_i le plus souvent utilisé, est une fenêtre carrée centrée sur le pixel x_i .

Afin d'incorporer l'information locale de l'image, nous présentons une nouvelle mesure de similarité « spectrale-locale (SL) FCM ». Pour ce faire, nous proposons une modification à l'équation (3.7) en incorporant un terme qui permet que l'étiquetage d'un pixel donné soit influencé par les étiquettes dans son voisinage immédiat, aussi bien que par l'homogénéité du pixel à l'étude.

La fonction de similarité modifiée est donnée par la distance D_{ij} :

$$D_{ij} = d_{ij}^2 \cdot g(\mathbf{x}_j, \mathbf{w}_j, v_i, h_j) \quad (3.10)$$

d_{ij} est la distance euclidienne qui mesure la similitude entre le pixel x_j et la classe v_i dans l'espace des attributs multispectrales. Elle est donnée par :

$$d_{ij}^2 = (v_i - x_j)^T (v_i - x_j) \quad (3.11)$$

g est une fonction locale, incluant l'homogénéité et la classification spatiale floue de chaque pixel considéré.

La fonction locale de poids est définie telle que:

$$g(\mathbf{x}_j, \mathbf{w}_j, \mathbf{v}_i, h_j) = \frac{\sum_{x_k \in \mathbf{w}_j} e^{(-h_j \cdot u_{ik})}}{\sum_{x_k \in \mathbf{w}_j} \sum_{l=1}^c e^{(-h_j \cdot u_{lk})}} \quad (3.12)$$

Où \mathbf{w}_j est l'ensemble des pixels voisins dans la fenêtre autour de \mathbf{x}_j ,

La fonction g est calculée sur la fenêtre locale \mathbf{w} centrée sur le pixel \mathbf{x}_j (une fenêtre 3x3 est utilisée dans notre approche),

\mathbf{v}_i est le centre de la $i^{\text{ème}}$ classe,

u_{ik} représente la probabilité que le $k^{\text{ème}}$ pixel de \mathbf{w}_j appartient à la $i^{\text{ème}}$ classe,

h_j est la valeur d'homogénéité du pixel central \mathbf{x}_j calculée sur la fenêtre locale \mathbf{w} .

L'homogénéité est apparentée à l'information locale extraite d'une image et reflète le degré d'uniformité d'une région donnée [Cheng et Sun 2000].

Cheng and Sun, ont utilisé le domaine d'homogénéité pour incorporer l'information locale et globale dans le procédé de la segmentation. Les auteurs ont étendu la notion de l'histogramme dans le domaine de l'homogénéité.

Jing *et al.* [Jing *et al.* 2003] ont présenté une méthode de segmentation basée sur l'analyse d'homogénéité locale et la croissance de régions. Les auteurs ont utilisé une mesure d'homogénéité basée sur l'intensité et la position des pixels.

Pour calculer l'homogénéité, nous avons considéré la mesure d'homogénéité basée sur l'intensité et la position [Jing *et al.* 2003].

La valeur de l'homogénéité h_j est définie par la norme de f tel que:

$$f = \sum_{\substack{x_k \in w_j \\ x_k \neq x_j}} d_{jk} \cdot \frac{p_{jk}}{\|p_{jk}\|} \quad (3.13)$$

$$h_j = \|f\| \quad (3.14)$$

Le pixel j est le centre de la fenêtre locale w (une fenêtre 3×3 pixels est utilisée pour calculer l'homogénéité),

w_j est l'ensemble des pixels voisins dans la fenêtre autour du pixel j sous étude,

d_{jk} est la distance euclidienne spatiale calculée entre les pixels x_j et x_k sur w_j ,

x_j and x_k sont des vecteurs contenant les valeurs des attributs spectraux des pixels j and k dans chaque canal,

p_{jk} est un vecteur de position défini tel que:

$$p_{jk} = (m - y, n - z) \quad (3.15)$$

Où (m, n) et (y, z) dénote la location du pixel central x_j et le pixel voisin x_k dans le domaine spatial.

3.2.1.3. Classification (SL) FCM

Dans l'algorithme FCM modifié, la matrice d'appartenance U , formée des valeurs U_{ij} , est mise à jour comme une fonction de distance D_{ij} entre les pixels à classer et les centres de classes:

$$U_{ij} = \frac{1}{\sum_{l=1}^c \left(\frac{D_{ij}}{D_{lj}} \right)^{\frac{1}{m-1}}} \quad (3.16)$$

Les prototypes des classes V_i sont calculés en utilisant les valeurs d'appartenance U_{ij} :

$$V_i = \frac{\sum_{j=1}^N U_{ij}^m \cdot \mathbf{x}_j}{\sum_{j=1}^N U_{ij}^m} \quad (3.17)$$

3.2.2. Algorithme de fusion de régions

Dans cette section, nous présentons l'algorithme de fusion de régions utilisé dans le processus de fusion des régions. Cet algorithme, utilise la classification agglomérative hiérarchique [Jain *et al.* 1999] et la matrice d'appartenance floue.

Supposons que C classes $\{C_i, i=1,2,\dots,C\}$ ont été obtenues dans l'étape précédente de l'algorithme de segmentation. Dans chaque classe C_i , U_{ij} représente le vecteur d'appartenance de tous les pixels de l'image à la classe C_i . V_i dénote le prototype de C_i .

D'abord, la matrice de proximité contenant la distance entre chaque paire de classes est calculée. Ensuite, on fixe le seuil de fusion de classes tel que :

$$T_d = \mu_d - a \cdot \sigma_v \quad (3.18)$$

Où :

μ_d et σ_v représentent respectivement la moyenne et l'écart type de la liste de différences dans la matrice de proximité.

a est un paramètre réglable choisi par l'utilisateur.

Dans l'algorithme de fusion, la paire la plus semblable des classes C_i et C_k ayant la plus petite distance dans la matrice de proximité, est d'abord située. Si cette distance minimum est plus petite que le seuil T_d , la classe C_i et la classe C_k peuvent être fusionnés pour former une nouvelle classe $C_{k'}$.

Le vecteur d'appartenance de la nouvelle région est donné par:

$$U_{k'j} = U_{ij} + U_{kj} \quad (3.19)$$

Le prototype de la classe de la région obtenu est calculé tel que:

$$\mathbf{V}_{k'} = \frac{\sum_{j=1}^N U_{k'j}^m \cdot \mathbf{x}_j}{\sum_{j=1}^N U_{k'j}^m} \quad (3.20)$$

Ensuite, la matrice d'appartenance floue et la matrice de proximité sont mises à jour. Le processus de fusion est effectué à répétition jusqu'à ce qu'aucune différence de classe ne soit plus petite que le seuil T_d .

Après la fusion, le résultat final de la segmentation est obtenu.

3.2.3. Algorithme de segmentation

Dans l'algorithme de segmentation, le nombre de classes est réduit dynamiquement. A chaque itération, l'algorithme de segmentation procède avec la nouvelle partition jusqu'à obtenir le résultat final de la segmentation.

L'algorithme de segmentation peut être récapitulé dans les étapes suivantes :

- (1) Fixer le nombre de prototypes de classes C , le paramètre flou m et le seuil d'arrêt ξ (dans nos expériences m et ξ sont fixés tels que : $m=2$, $\xi=0,001$).
- (2) Initialiser aléatoirement la matrice de prototypes des classes \mathbf{V}
- (3) Initialiser le compteur d'itérations $It = 0$

- (4) Calculer l'homogénéité h_j suivant la fenêtre \mathbf{w}
- (5) Calculer la fonction locale des poids en utilisant $g(\mathbf{x}_j, \mathbf{w}_j, \mathbf{v}_i, h_j)$
- (6) En utilisant g calculer la matrice de distance de similarité locale \mathbf{D} .
- (7) Calculer les valeurs des degrés d'appartenance U_{ij} en utilisant \mathbf{D}
- (8) Calculer les prototypes des classes \mathbf{V}_i
- (9) Si la condition d'arrêt suivante est satisfaite, $\text{Max}\{\mathbf{V}(\mathbf{b})-\mathbf{V}(\mathbf{b}+\mathbf{1})\} < \xi$ aller à l'étape suivante, autrement aller à l'étape 4.
- (10) Fusionner les classes, en utilisant le processus de fusion de régions proposé. Si le nombre de classes change, mettre $It = It + 1$, ensuite aller à l'étape 4 et répéter la totalité de la procédure selon le nouveau nombre de classes C , la matrice d'appartenance \mathbf{U} et les prototypes de classes \mathbf{V} . Si C ne change pas, arrêter la procédure.

Une fois que le nombre de classes final est obtenu, chaque pixel de l'image est assigné à la classe correspondante. Cette procédure assigne le pixel \mathbf{x}_j à la classe i ayant la valeur d'appartenance la plus grande telle que:

$$c_{ij} = \arg_i \{ \max \{ u_{ij} \} \}, i = 1, 2, \dots, C \quad (3.21)$$

3.3. Résultats et discussion

3.3.1. Application aux images synthétiques

L'approche décrite dans la section précédente a été d'abord testée sur des images synthétiques obtenues à partir de la base de données d'images de texture de couleur du site Web (Colombia database). Les images synthétiques sont celles données par les figures 2.5 et 2.6 du chapitre précédent.

Dans la première expérience, les images synthétiques ont été traitées en utilisant l'approche proposée. La figure 3.1 montre le résultat de la segmentation de la figure 2.5 pour un paramètre de fusion de 0.8 et un seuil de fusion de 0.2548. Les paramètres choisis donnent un taux de bonne segmentation optimal de 98,72%. Comme pour l'image originale, la figure 3.1 est

composée de quatre sortes de textures couleur. L'approche proposée donne une carte de segmentation cohérente et les contours des quatre carrés sont proprement reproduits.

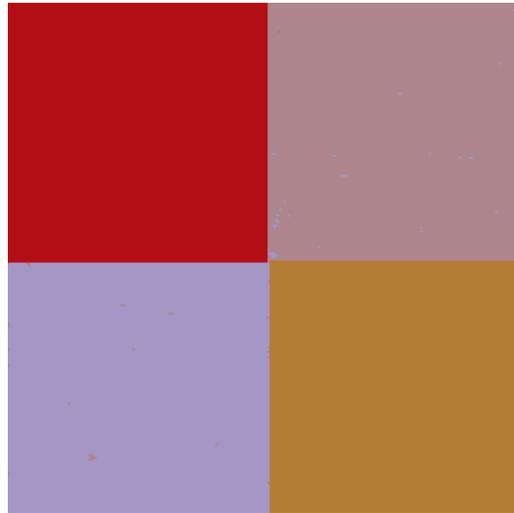


Figure 3.1. Segmentation de l'image synthétique de la figure 2.5 en utilisant l'approche LSF
(SA=98,72%)

La figure 3.2 montre le résultat de la segmentation de la figure 2.6 pour un paramètre de fusion de 0.9 et un seuil de fusion de 0.3825. Pour cette expérience, les paramètres choisis donnent un taux de bonne segmentation optimal de 98.23%. Comme pour l'image originale, la figure 3.2 est composée de trois sortes de textures couleur. L'approche proposée donne une carte de segmentation cohérente et les contours des quatre carrés sont proprement reproduits.

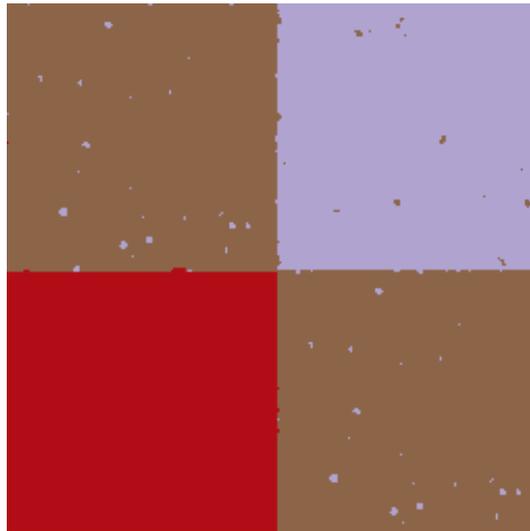


Figure 3.2. Segmentation de l'image synthétique de la figure 2.6 en utilisant l'approche LSF
(SA=98,23%)

Afin de montrer l'apport de l'approche LSF, celle-ci a été comparée avec les approches floues FCM, SFCM, et FLICM que nous avons développées.

Les tables 3.1 et 3.2 donnent les taux de bonne segmentation comparatifs des images des figures 2.5 et 2.6 respectivement.

Table 3.1. Taux de bonne segmentation (SA) pour les différentes approches

Approches	Taux de segmentation SA (%)
FCM	87,59%
SFCM	94,32%
FLICM	97,66%
LSF	98,72%

Table 3.2. Taux de bonne segmentation (SA) pour les différentes approches

Approches	Taux de segmentation SA (%)
FCM	87,36%
SFCM	94,16%
FLICM	97,35%
LSF	98,23%

Pour les images synthétiques, l'approche LSF rapporte des taux de segmentation optimaux de 98,72% et 98,23% respectivement. La contribution de l'approche proposée par rapport à l'algorithme FCM est de 11,13% et 10,87%, respectivement.

3.3.2. Application aux images MSG

Dans la troisième expérience, la méthode proposée est appliquée à un ensemble d'images Météosat Seconde Génération "MSG" enregistrées en Février 2012.

3.3.2.1. Présentation des données MSG

La base de données utilisées dans notre étude est constituée d'une série d'images 'MSG' dans les canaux du visible et infrarouge. Ces images ont été collectées durant le mois de février 2012. Elles représentent l'Afrique du Nord, la mer méditerranéenne, l'Europe de l'ouest et l'océan atlantique. Chaque image forme une fenêtre composée de 512x512 pixels, avec un niveau de gris allant de 0 à 255 et la dimension de chaque pixel est de 3kmx3km au point sous le satellite.

Pour illustrer le traitement d'image, trois images enregistrées dans l'IR1.6, VIS0.8 et VIS0.6 le 06 Février 2012 à 14 :00 UTC sont montrés sur les figures 3.3, 3.4, 3.5.

Les trois canaux représentent différentes propriétés physiques. Le canal VIS0.6 fournit l'épaisseur optique du nuage. Le canal VIS0.8 fournit une information sur l'indice de végétation et le canal IR1.6 permet de distinguer la neige sur terre des nuages. Une combinaison colorée des trois canaux est montrée sur la figure 3.6. Cette image a été construite en assignant les canaux IR1.6, VIS0.8 et VIS0.6 aux composantes rouge, vert et bleu, respectivement.

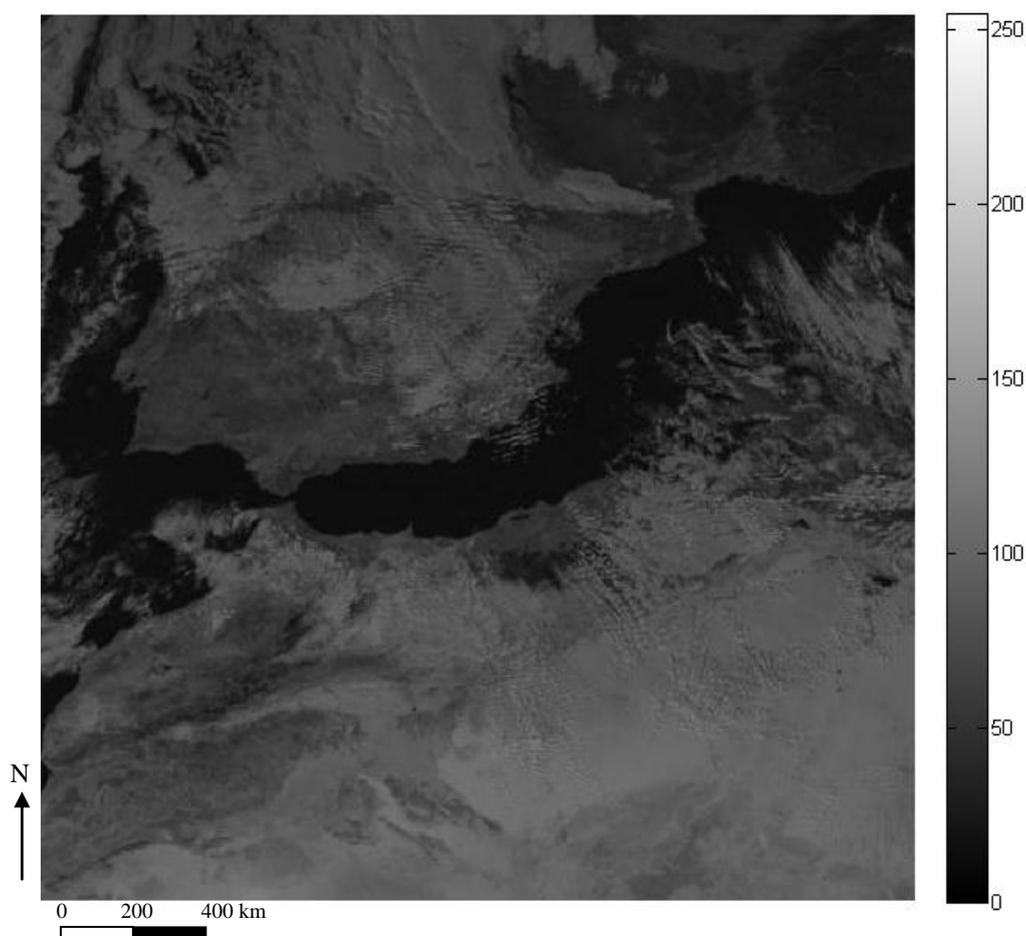


Figure 3.3. Image MSG dans le canal Infrarouge (1.6) acquise le 06 Février 2012 à 14:00 UTC, montrant l'Afrique du Nord, la mer Méditerranéenne, l'Europe de l'ouest et l'Atlantique

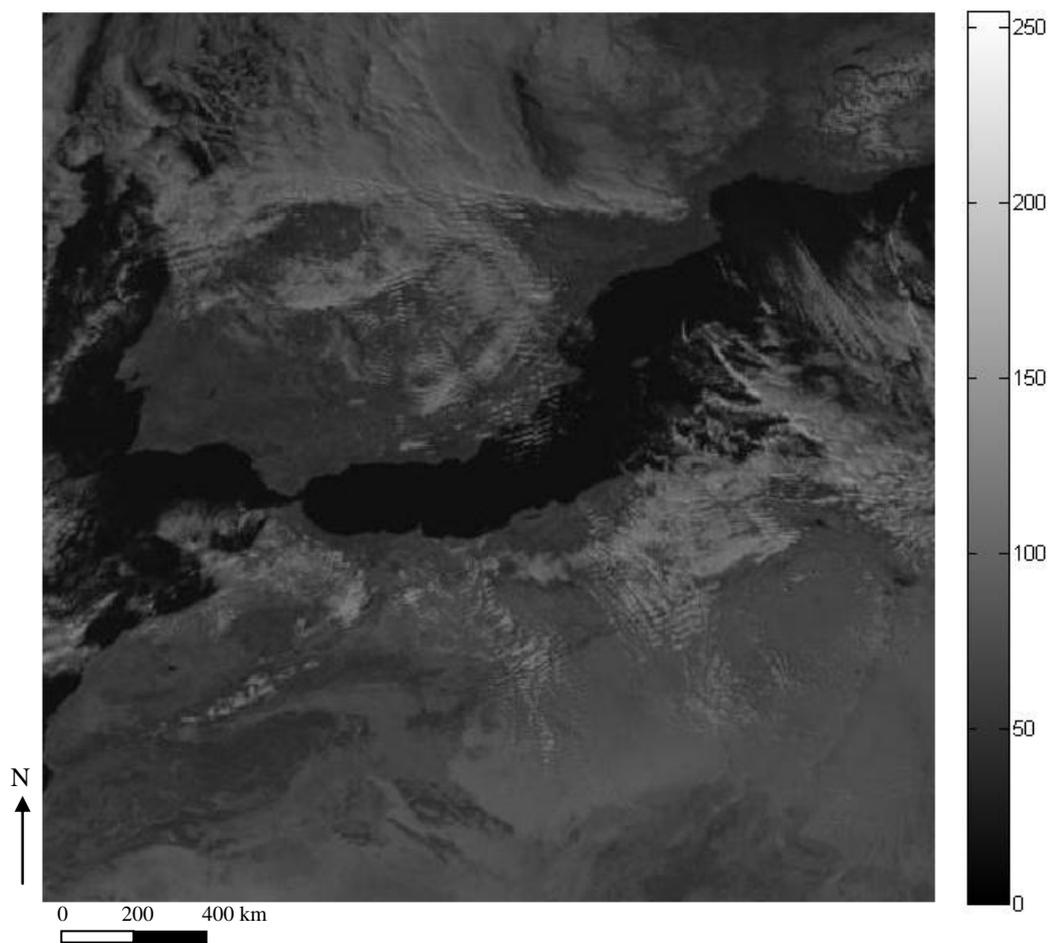


Figure 3.4. Image MSG dans le canal visible (0.8) acquise le 06 Février 2012 à 14:00 UTC, montrant l'Afrique du Nord, la mer Méditerranéenne, l'Europe de l'ouest et l'Atlantique.

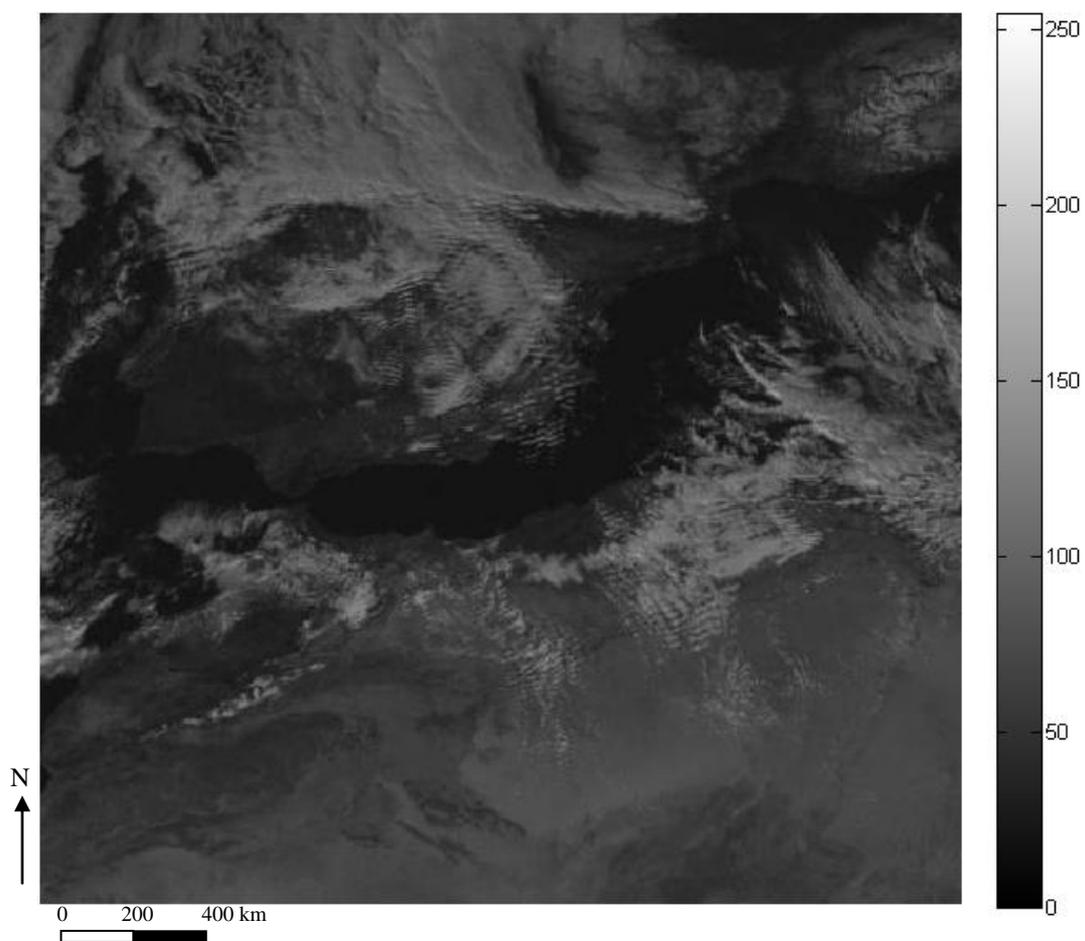


Figure 3.5. Image MSG dans le canal visible (0.6) acquise le 06 Février 2012 à 14:00 UTC, montrant l'Afrique du Nord, la mer Méditerranéenne, l'Europe de l'ouest et l'Atlantique.

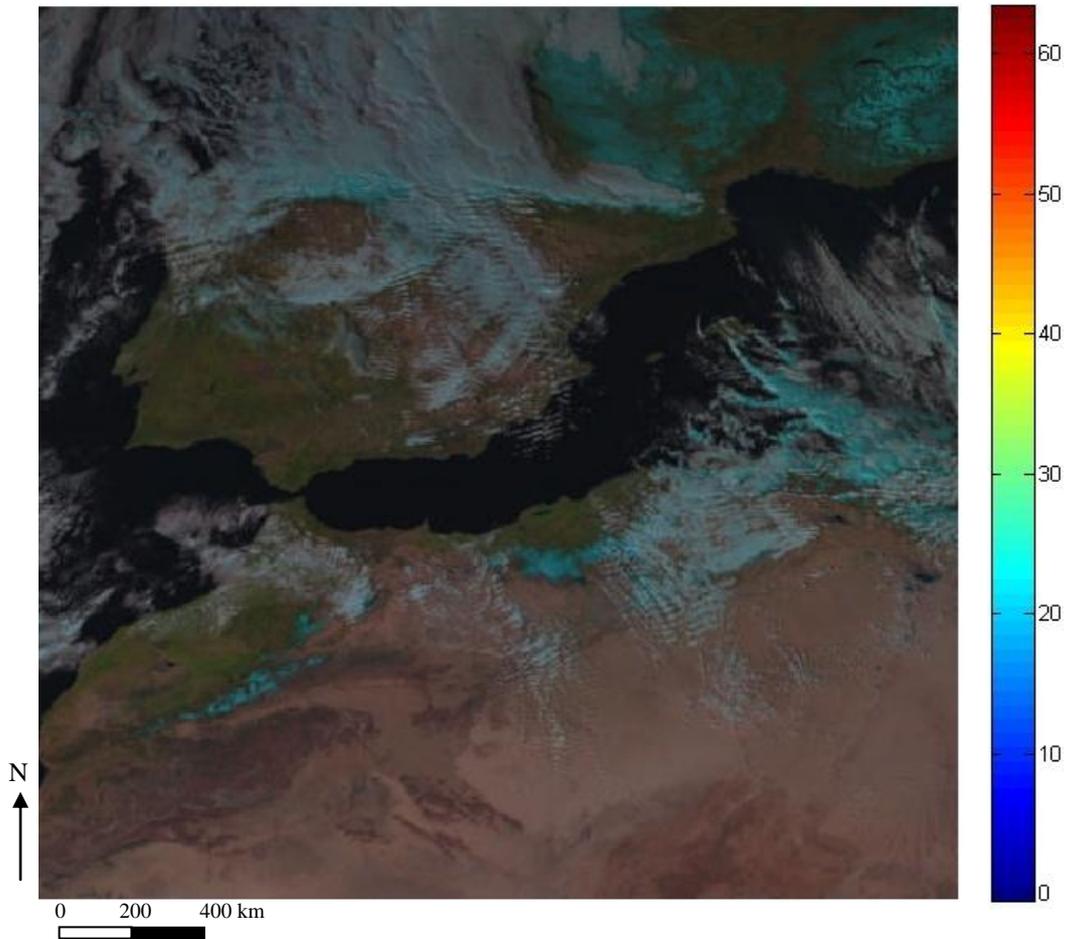


Figure 3.6. Image composite RVB, IR 1.6, VIS 0.8, VIS 0.6 acquise le 06 Février 2012 à 14:00 UTC, montrant l’Afrique du Nord, la mer Méditerranéenne, l’Europe de l’ouest et l’Atlantique.

Le choix des canaux IR 1.6, VIS 0.8, VIS 0.6 a été fait après étude des signatures spectrales dans les surfaces de scènes naturelles.

Dans l’image multispectrale résultante de la figure 3.6, les nuages apparaissent beige clair. Le faible éclat des nuages prouve qu’ils sont à basse altitude. La neige qui apparaît dans une partie de l’Afrique du Nord et de l’Europe apparaît en bleu cyan sur la combinaison colorée.

En effet, la neige absorbe une partie du rayonnement IR1.6 et réfléchit essentiellement dans le VIS0.6 et moins dans le VIS0.8.

Les surfaces désertiques ont une réflectance qui augmente légèrement depuis les courtes vers les plus grandes longueurs d'ondes. Elles apparaissent ainsi dans les teintes roses, saumon. La végétation réfléchissant essentiellement dans le VIS0.8, apparaît en vert sur la combinaison colorée. Enfin, l'eau qui absorbe fortement les rayonnements dans l'IR1.6 et dans VIS0.8 apparaît en bleu très sombre.

En analysant les figures 3.3, 3.4, 3.5 et 3.6 ensemble, la couverture de nuage peut être identifiée. Les nuages de cumulus et de stratocumulus couvrent une partie de l'Afrique du Nord et de l'Europe de l'ouest. Dans le stratocumulus, la couverture nuageuse demeure agglomérée et organisée en lignes ou plateaux. Les cumulus sont des nuages, séparés, généralement denses et avec des contours bien délimités. Les caractéristiques des nuages observés dans ces images, brouillées par des contours flous, rendent leur détection et leur séparation difficiles.

3.3.2.2. *Discussion des résultats*

Pour obtenir la segmentation appropriée des images MSG, l'information spectrale, l'homogénéité locale et l'information de classification spatiale floue sont considérées. La figure 3.7 donne le résultat de la segmentation des images MSG en sept classes homogènes, pour le paramètre de fusion de 1.2 et la valeur de seuil de fusion de 0.093. Ces classes sont représentées avec différentes couleurs sur la figure 3.8. Dans cette image, les deux genres de nuages précédemment identifiés sont représentés par les classes jaunes et marron clair. Ces dernières sont respectivement assignées au stratocumulus et aux nuages cumulus couvrant la plupart de l'Afrique du Nord.

Les deux sortes de nuages apparaissent au dessus du Nord de l'Algérie. Les observations au sol confirment que les nuages couvrant le nord de l'Algérie le 06 février 2012 étaient des nuages cumulus et stratocumulus. Ces nuages sont également présents au-dessus de la mer méditerranéenne, de l'Europe de l'ouest et du Nord Atlantique. Dans les régions à ciel clairs s'étendant au-dessus de l'Afrique du Nord et de l'Europe, la neige est assignée à la classe pourpre.

L'Océan Atlantique et la mer méditerranéenne sont assignés à la classe marron foncée. Le désert saharien et la végétation sont représentés par les classes rouge et vert, respectivement. Enfin la classe bleue est attribuée aux montagnes d'atlas et du Bétique.

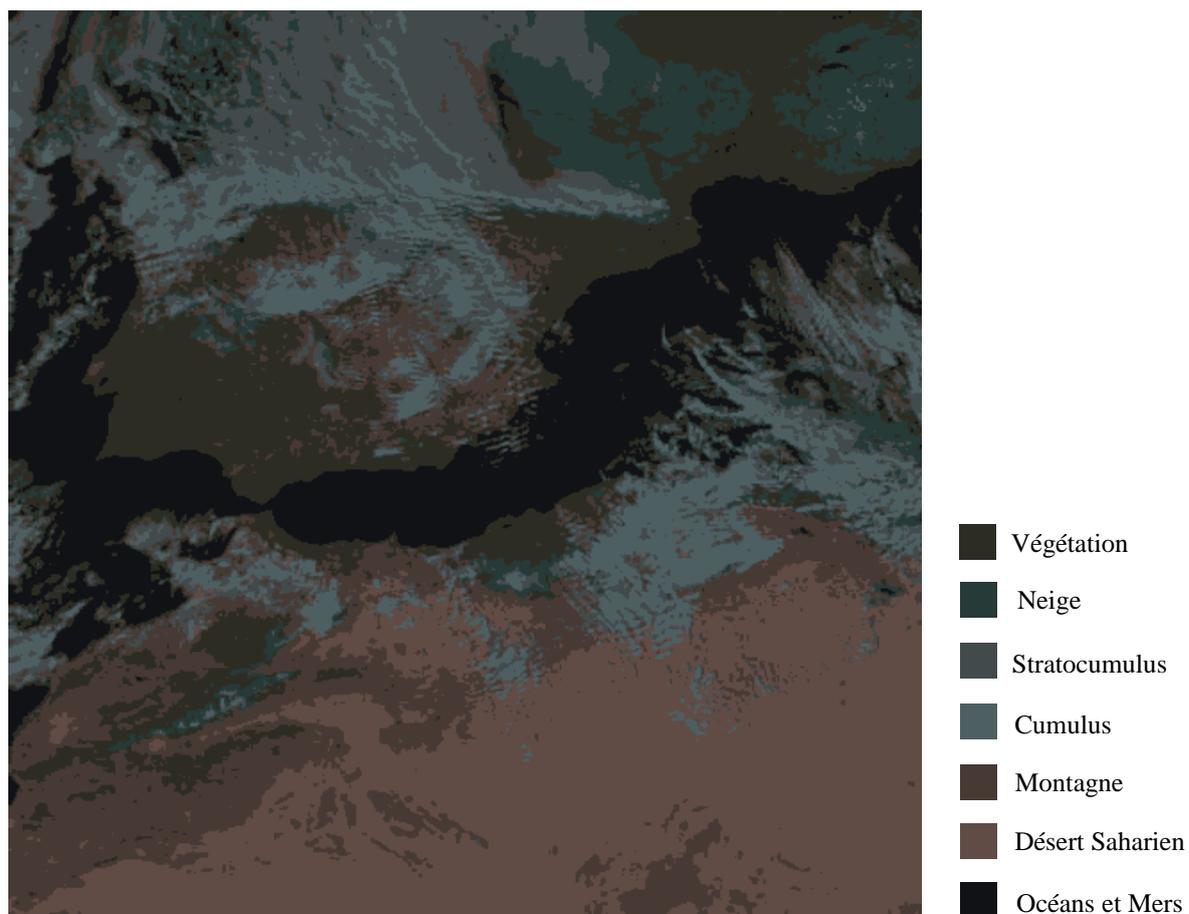


Figure 3.7. Segmentation de l'image multispectrale MSG en 7 classes homogènes

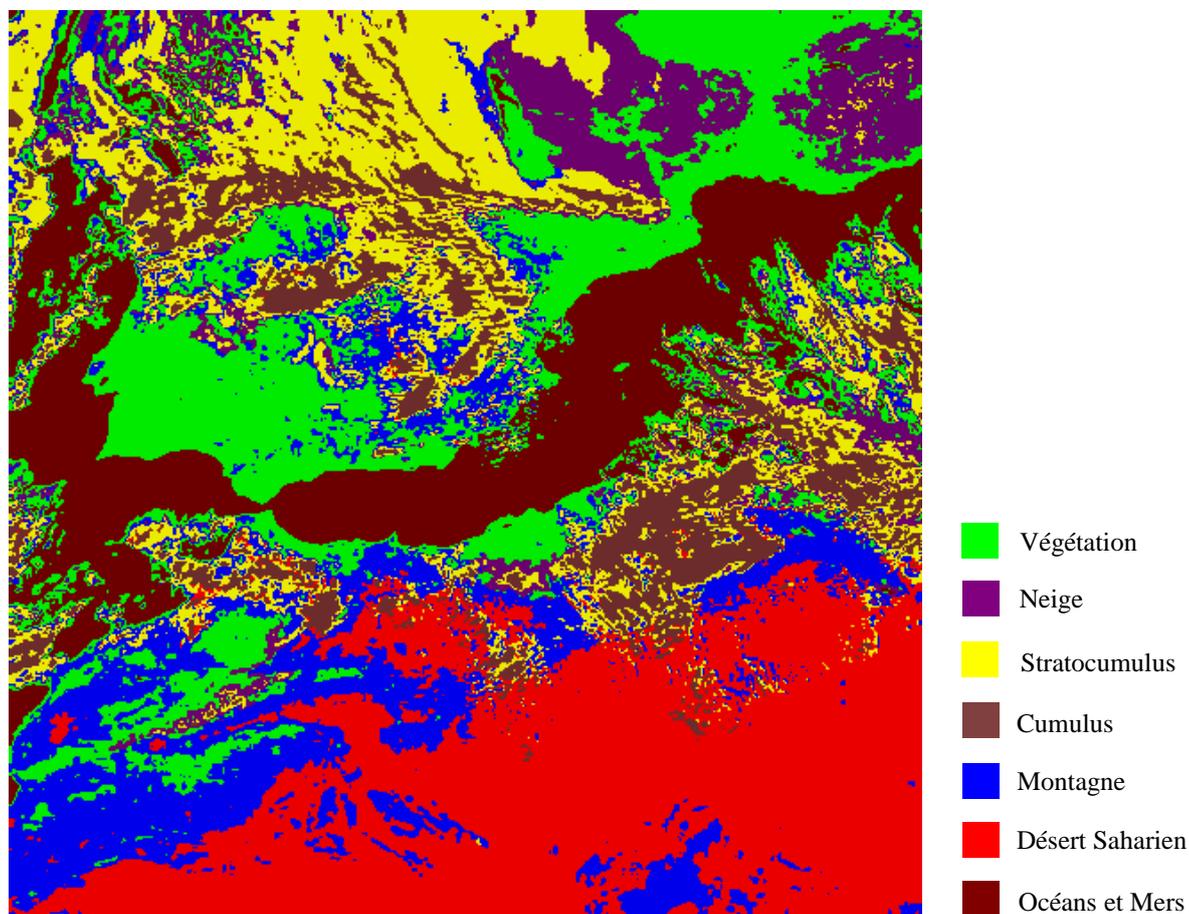


Figure 3.8. Segmentation de l'image multispectrale MSG en 7 classes homogènes représentées avec différentes couleurs

3.4. Discussion

Les résultats obtenus ont prouvé que la méthode proposée a correctement détecté les nuages, les sols et les mers dans les images MSG acquises le 06 février 2012. La méthode itérative de segmentation présentée dans les sections précédentes est basée sur la classification locale-spectrale floue et le processus de fusion des régions. La classification locale-spectrale floue est effectuée en incorporant l'homogénéité locale et la classification spatiale dans la mesure de similarité de l'algorithme de FCM. Les classes obtenues sont alors fusionnées en utilisant un processus de fusion de régions hiérarchique.

A chaque itération, le nombre de classes est réduit dynamiquement jusqu'à obtenir le résultat final de la segmentation. Malgré la complexité des détails composant ces images, notre approche rapporte une carte de segmentation compacte et cohérente, avec la reproduction satisfaisante des contours des images. Pour améliorer plus les performances de segmentation, nos investigations à l'avenir seront orientées à spécifier automatiquement un seuil approprié pour le processus de fusion de régions.

CHAPITRE 4

SEGMENTATION PAR FILTRAGE DE GABOR ET ANALYSE D'HOMOGENÉITÉ LOCALE

4.1. Problématique

Avec l'apparition de capteurs imageurs de plus en plus performants, un nombre énorme d'images, avec une résolution spectrale et spatiale très élevée, sont produites à chaque instant. Par conséquent, il est nécessaire d'élaborer de nouvelles méthodes de segmentation qui permettent de détecter les régions d'intérêt dans les images multispectrales, riches en information.

Durant le processus de la segmentation, plusieurs caractéristiques peuvent être considérées: l'intensité en niveau de gris, la couleur, la forme, et les attributs de la texture...etc. La texture peut être définie comme une région avec des variations d'intensité. Elle peut être aussi définie comme un arrangement répétitif de motifs dans une région [Schwartz and Pedrini 2007].

La segmentation de la texture dans les images numériques a reçu un intérêt particulier durant ces dernières années [Chen 1993 ; Deng et Manjunath 2001 ; Zhang *et al.* 2002 ; Aneur et al. 2004 ; Schwartz and Pedrini 2007]. Les techniques utilisées pour l'extraction des attributs de la texture sont principalement de trois sortes : structurelles, statistiques et spectrales. Ces approches utilisent généralement des stratégies de segmentation qui ignorent les corrélations

spectrales existant entre les pixels de l'image. En effet, l'utilisation conjointe de l'information spectrale et texturale peut améliorer le résultat de la segmentation.

Dans l'analyse de la texture, les approches fréquentielles ont été largement utilisées dans les images en niveau de gris. Parmi celles-ci, on trouve le filtrage de Gabor et la décomposition en ondelettes. Les filtres de Gabor décomposent l'image en plusieurs composantes correspondant à différentes échelles et orientations.

Dans ce chapitre, nous présentons une nouvelle méthode de segmentation d'images multispectrales basée sur la classification floue des textures spectrales et l'analyse de l'homogénéité locale. Dans les sections suivantes, l'approche proposée sera décrite puis évaluée en utilisant des images synthétiques et multispectrales MSG.

4.2. Description de la méthode

L'approche proposée [Bitam, Ameer 2013], est basée sur la classification floue des textures spectrales et l'analyse d'homogénéité locale (FGAHL). La méthode comporte deux étapes. Dans la première étape, le filtrage de Gabor est utilisé pour extraire les attributs de texture de chaque bande spectrale de l'image. En utilisant l'analyse de Gabor, les images sont analysées à différentes échelles et orientations. Les textures spectrales obtenues sont ensuite combinées puis classées en utilisant l'algorithme de classification floue FCM, on obtient ainsi une segmentation initiale de l'image. Dans la deuxième étape, une analyse d'homogénéité locale est effectuée en utilisant un critère de segmentation. L'analyse d'homogénéité est appliquée à la carte de régions afin d'obtenir le résultat final de la segmentation.

4.2.1. Extraction des attributs de texture

Pour caractériser les attributs de textures spectrales de l'image, le filtrage de Gabor est appliqué à chaque bande spectrale de l'image. Ainsi, pour chaque canal de l'image, un ensemble d'images filtrées à différentes échelles et orientations sont obtenues.

Afin de déterminer les attributs de la texture, [Jain et Farrokhinia 1991] ont proposé un algorithme qui permet d'extraire ces attributs à partir des images filtrées. Dans un premier temps,

une transformation non linéaire est appliquée à chacune des images filtrées. Ensuite, sur chaque image réponse obtenue, on applique une fenêtre Gaussienne dont l'écart type σ détermine la taille de la fenêtre utilisée. Ce processus génère une « image attribut » pour chacune des images réponse. L'algorithme d'extraction des attributs de texture, à partir de chaque bande spectrale, est résumé dans la figure 4.1.

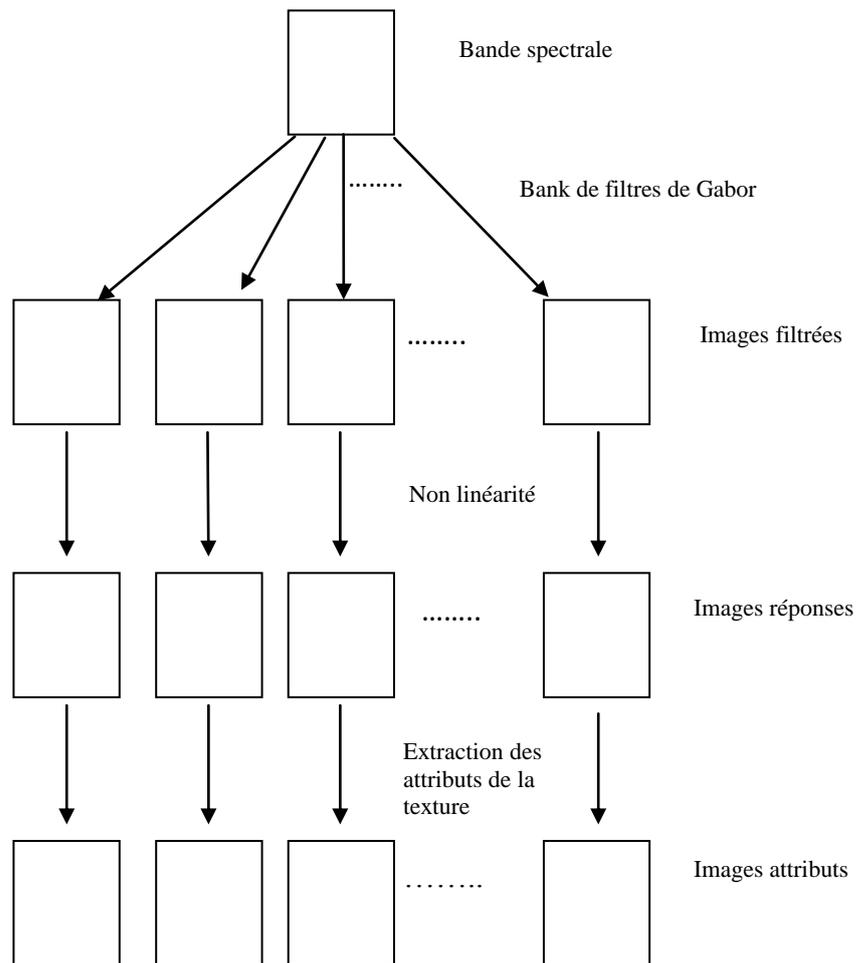


Figure 4.1. Description de l'algorithme d'extraction des attributs de texture

4.2.1.1. Caractérisation du canal

Dans notre approche, chaque canal de l'image est représenté avec une banque de filtres de Gabor bidimensionnels. La fonction de Gabor 2D consiste en une onde plane sinusoïdale avec quelques fréquences et orientations, modulée par une enveloppe gaussienne bidimensionnelle.

Le filtre de Gabor dans le domaine spatial est donné par [Jain et Farrokhinia 1991]:

$$h(x, y) = \exp\left\{-\frac{1}{2}\left(\frac{x'^2}{\sigma_x^2} + \frac{y'^2}{\sigma_y^2}\right)\right\} \cos\left(2\pi \frac{x'}{\lambda} + \varphi\right) \quad (4.1)$$

Où:

$$\begin{aligned} x' &= x \cos(\theta) + y \sin(\theta), \\ y' &= y \cos(\theta) - x \sin(\theta) \end{aligned} \quad (4.2)$$

Dans cette équation :

λ représente la longueur d'onde du facteur cosinus,

θ peut être obtenu via une rotation rigide du système de coordonnées x - y ,

φ est la phase en degrés de l'onde plane sinusoïdale selon l'axe des x ,

σ_x et σ_y sont les écarts types de l'enveloppe Gaussienne selon les axes x et y ,

$f = 1/\lambda$ est la fréquence spatiale du facteur cosinus.

Pour un filtre de Gabor isotrope $\sigma_x = \sigma_y$, le rapport σ/λ est donné par la relation suivante [Zhang *et al.* 2002]:

$$\frac{\sigma}{\lambda} = \frac{\sqrt{2 \ln 2}}{2\pi} \frac{2^B + 1}{2^B - 1} \quad (4.3)$$

Le rapport σ/λ est contrôlé par largeur de bande B du filtre de Gabor.

La fréquence de la largeur de bande B (en octaves) de la fréquence f_1 à la fréquence f_2 est donnée par:

$$B = \log_2\left(\frac{f_1}{f_2}\right) \quad (4.4)$$

Les fréquences f_1 et f_2 correspondent à l'amplitude de la mi-crête de la réponse du filtre de Gabor circulaire. Dans notre approche, on fixe la largeur de bande du filtre de Gabor à 1 octave.

4.2.1.2. Choix des paramètres des filtres

On utilise un angle d'orientation de séparation de 45° tel que recommandé dans [Jain et Farrokhinia 1991]:

$$\theta = 0^\circ, 45^\circ, 90^\circ, 135^\circ, 180^\circ \quad (4.5)$$

Pour une image texturée de dimension $N \times N$, la fréquence f est souvent choisie telle que [Jain et Farrokhinia 1991 ; Zhang *et al.* 2002]:

$$\sqrt{2}\{1, 2, 4, 8, 16, \dots, N/4\}/N \quad (4.6)$$

La valeur de la fréquence est normalisée par N .

N est la largeur de l'image qui est une puissance de 2.

4.2.1.3. Extraction des attributs de textures de l'image

Jain [Jain et Farrokhinia 1991] suggère d'utiliser une fonction sigmoïdale non linéaire donnée par :

$$\tanh(\alpha t) = \frac{1 - e^{-2\alpha t}}{1 + e^{-2\alpha t}} \quad (4.7)$$

Où α est une constante (la valeur $\alpha=0.25$ a été choisie).

Afin d'extraire les attributs de la texture, Jain [Jain et Farrokhinia 1991] suggère aussi d'appliquer une fonction de lissage Gaussienne sur chaque image filtrée.

La fonction est donnée par la relation:

$$g(x, y) = \exp\left\{-\frac{x^2 + y^2}{2\sigma^2}\right\} \quad (4.8)$$

Où σ est l'écart type qui détermine la taille de la fenêtre. La valeur de σ est donnée par la relation (4.3).

4.2.2. Classification des textures multispectrales

Dans cette étape, les vecteurs d'attributs de textures, obtenus pour chaque pixel de l'image, vont être combinés puis classés en utilisant l'algorithme de classification floue *FCM*.

Supposons que le nombre total des bandes spectrales dans l'image est K .

Le vecteur de coefficients obtenu à partir de la $K^{\text{ème}}$ bande spectrale est donné par :

$$f_k = [c_{00}^k, c_{01}^k, c_{02}^k, \dots, c_{MN}^k] \quad (4.9)$$

c_{MN} sont les coefficients de transformations obtenus pour M échelles et N orientations.

K est le nombre de bandes spectrales de l'image.

Les vecteurs d'attributs obtenus à partir de K bandes spectrales sont ensuite combinés en un seul vecteur \mathbf{f} tel que :

$$\mathbf{f} = [f_1, f_2, \dots, f_k, \dots, f_K] \quad (4.10)$$

Le vecteur \mathbf{f} caractérise tous les canaux de l'image. Ce vecteur est constitué de coefficients de transformation obtenus pour M échelles, N orientations, et K bandes spectrales.

L'algorithme de classification c-moyennes floues (FCM) est ensuite utilisé pour classer les vecteurs de textures multispectrales des pixels de l'image. On obtient ainsi une segmentation initiale de l'image.

L'algorithme FCM est basé sur la minimisation de la fonction objective suivante:

$$J = \sum_{j=1}^N \sum_{i=1}^C u_{ij}^m \|\mathbf{f}_j - \mathbf{v}_i\|^2 \quad (4.11)$$

Où \mathbf{f}_j représente le vecteur d'attribut de textures spectrales du $j^{\text{ème}}$ pixel de l'image,

u_{ij} représente le degré d'appartenance du pixel j au centre de la $i^{\text{ème}}$ classe \mathbf{v}_i ;

\mathbf{v}_i est le centre multidimensionnel de la $i^{\text{ème}}$ classe, $\|\ \|\$ est une norme métrique mesurant la similarité entre le pixel j et le centre \mathbf{v}_i , et m est un paramètre flou de la partition résultante.

- 1) Supposer que $\mathbf{x}=(f_1, f_2, \dots, f_j, \dots, f_d)$ les attributs spectraux des textures de l'image à partitionner, où d est le nombre de pixels de l'image. On choisit le nombre de classes C , le paramètre flou m et la condition d'arrêt ξ .
- 2) Initialiser \mathbf{u} en utilisant une valeur aléatoirement choisie dans l'intervalle $[0,1]$.
- 3) Fixer le compteur de boucle $b = 0$
- 4) Calculer le centre de classe \mathbf{v}_i :

$$\mathbf{v}_i = \frac{\sum_{j=1}^N u_{ij}^m \cdot \mathbf{f}_j}{\sum_{j=1}^N u_{ij}^m} \quad (4.12)$$

5) Mettre à jour u_{ij} comme une fonction de distance aux centres de classes:

$$u_{ij} = \frac{1}{\sum_{l=1}^c \left(\frac{d_{ij}^2}{d_{lj}^2} \right)^{\frac{1}{m-1}}} \quad (4.13)$$

6) Si $\text{Max}\{\mathbf{u}(b)-\mathbf{u}(b+1)\} < \xi$ alors arrêt, sinon, mettre $b=b+1$ et aller à l'étape 4.

4.2.3. Analyse d'homogénéité locale

Après les étapes de filtrage et de classification, une segmentation initiale de l'image est obtenue. La carte de régions ainsi obtenue est ensuite analysée en utilisant un critère de segmentation [Deng et Manjunath 2001].

Deng et Manjunath ont proposé un concept pour tester l'homogénéité d'un motif donné dans une carte de classes. Afin d'utiliser le critère de segmentation, une carte de classes de l'image a été construite. Dans la carte de classes, les attributs des pixels sont remplacés par les labels de classes correspondants.

Le critère de Deng et Manjunath pour la segmentation:

Soit Z l'ensemble de tous les N pixels dans la carte de classes, $z=(x, y)$, $z \in Z$ les coordonnées de chaque point, et m la moyenne du vecteur, alors nous avons:

$$m = \frac{1}{N} \sum_{z \in Z} z \quad (4.14)$$

Supposons que le nombre total de régions obtenues après l'étape de classification est égale à C , c'est à dire, Z est classé en C classes, Z_i , $i=1...C$, alors le vecteur moyen pour chaque classe est donné par :

$$m_i = \frac{1}{N_i} \sum_{z \in Z_i} z \quad (4.15)$$

La variance inter-classes est donnée par :

$$S_T = \sum_{z \in Z} \|z - m\|^2 \quad (4.16)$$

La variance intra-classes est donnée par :

$$S_W = \sum_{i=1}^C S_i = \sum_{i=1}^C \sum_{z \in Z_i} \|z - m_i\|^2 \quad (4.17)$$

La valeur J de la carte de classes peut être définie telle que:

$$J = \frac{S_T - S_W}{S_W} \quad (4.18)$$

L'analyse d'homogénéité locale et la segmentation spatiale sont décrites dans les étapes suivantes:

- (1) Calculer la valeur J locale en utilisant une petite fenêtre centrée sur chaque pixel de l'image (une fenêtre de dimension 9x9 est choisie). Après ce processus, une autre image est construite, avec les valeurs des pixels égales à ces valeurs de J .
- (2) Calculer la moyenne et la variance de ces J valeurs locales notées m_J and σ_J et fixer le seuil à :

$$T_J = m_J + \mu \sigma_J \quad (4.19)$$

- (3) Traverser tous les pixels de l'image, et déterminer ceux qui ont les valeurs de J inférieures à T_J et considérer ces pixels comme des pixels germes candidats (pour la sélection des pixels germes candidats, on fixe la valeur de μ à 0).

Relier ces points germes candidats en se basant sur la règle de 4-connectivité afin d'obtenir quelques régions. Les régions ayant une surface plus grande qu'un seuil prédéfinie sont considérées comme des régions germes.

- (4) A partir de ces germes, faire croître les pixels restants un par un jusqu'à ce que tous les pixels soient classés, où le pixel avec la plus petite valeur de J a la plus grande priorité d'être traité.
- (5) Calculer l'histogramme pour chaque région, et ensuite fusionner les régions voisines selon la distance entre leurs histogrammes respectifs.

4.3. Résultats et discussions

4.3.1. Application aux images synthétiques

L'approche proposée a été testée sur des images synthétiques obtenues à partir de la base de données d'images de textures couleur du site Web (Colombia database). Les images synthétiques sont celles données par les figures 2.5 et 2.6 du deuxième chapitre.

Les figures 4.2, 4.3 et 4.4 donnent les résultats de la classification floue des textures des trois composantes Rouge, Verte, et Bleu de l'image synthétique de la figure 2.5. Le résultat de la classification floue des textures multispectrales est donné par la figure 4.5. Les régions obtenues sont représentées en assignant une couleur à chaque région segmentée. Dans ce test, 7 échelles et quatre orientations ont été utilisées, à savoir $\theta = 0^\circ, 45^\circ, 90^\circ, 135^\circ$. Les fréquences ont été choisies en utilisant la relation (4.6) : $\sqrt{2}\{1, 2, 4, 8, 16, 32, 64\}/256$.

La table 4.1 donne les taux de bonne segmentation comparatifs obtenus pour les images composantes rouge, vert, bleu, et l'image RVB. Les résultats montrent l'apport de la caractérisation des textures multispectrales. En effet, la classification floue des textures multispectrales dans l'espace spectrale RVB rapporte un taux de bonne segmentation optimal de 97,16%. Les résultats de la classification scalaire des composantes rouge, vert, et bleu montrent que le résultat de la segmentation dépend de la composante couleur utilisée.

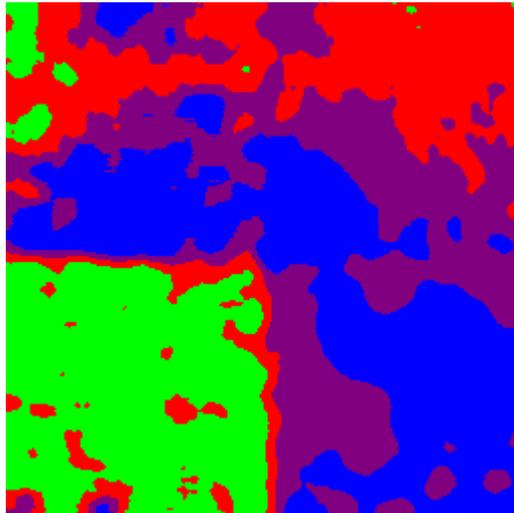


Figure 4.2. Résultat de la segmentation de la composante rouge
(SA= 44,95%)

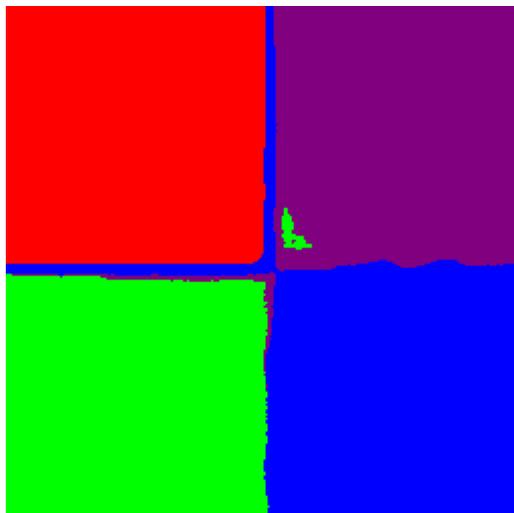


Figure 4.3. Résultat de la segmentation de la composante verte
(SA= 96,32%)

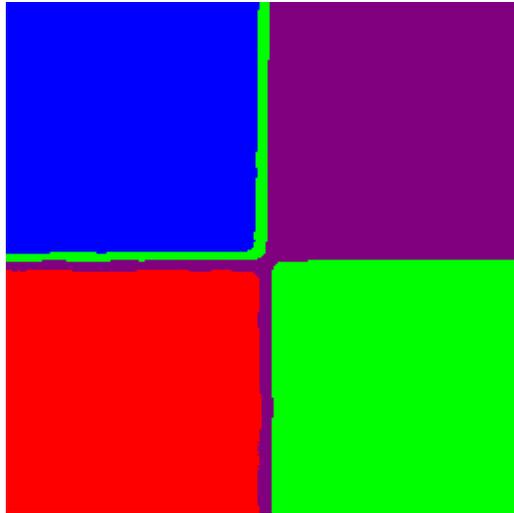


Figure 4.4. Résultat de la segmentation de la composante bleu
(SA= 95,70%)

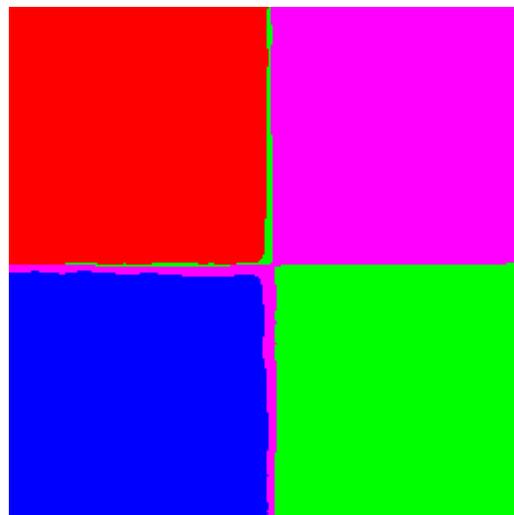


Figure 4.5. Résultat de la segmentation de l'image RVB
(SA= 97,16%)

Tableau 4.1. Taux de bonne segmentation (SA) pour les différentes composantes couleur

Composante couleur	Taux de segmentation SA (%)
R	44.95%
V	96.32%
B	95,70%
RVB	97.16%

Les figures 4.6, 4.7 et 4.8 montrent les résultats de segmentation obtenus après application de l'algorithme d'analyse d'homogénéité locale, pour un seuil de fusion de 0.4. Ces résultats ont été obtenus après l'analyse d'homogénéité effectuée sur les images résultats des figures 4.3, 4.4, et 4.5 respectivement. Les régions obtenues sont représentées en assignant une couleur à chaque région segmentée. La table 4.2 donne les taux de bonne segmentation comparatifs obtenus pour les images rouge, vert, bleu, et RVB.

Les résultats de segmentation montrent que les régions obtenues sont compactes et cohérentes, avec une détection satisfaisante des contours. Cependant, on remarque que le résultat de la segmentation dépend de la carte de régions obtenue après l'étape de classification des textures. Ainsi, l'analyse de la carte de régions des textures multispectrales, de la figure 4.5, rapporte un taux de bonne segmentation optimal de 98,46%. Comme dans l'image originale, la figure 4.8 est constituée de quatre régions représentant les 4 types de textures fines.



Figure 4.6. Résultat de la segmentation de la composante Verte
(SA= 96,97%)



Figure 4.7. Résultat de la segmentation de la composante Bleue
(SA= 96,23%)



Figure 4.8. Résultat de la segmentation de l'image synthétique couleur
(SA= 98,46%)

Table 4.2. Taux de bonne segmentation (SA) pour différentes composantes couleur avant et après analyse d'homogénéité

Composante couleur	Taux de segmentation SA (%)	Taux segmentation après l'analyse d'homogénéité SA (%)
R	44,95%	45,05%
V	96,32%	96,97%
B	95,70%	96,23%
RVB	97,16%	98,46%

L'approche proposée a été également testée en utilisant l'image de la figure 2.6 composée de trois textures couleur grossières. Le résultat de segmentation de l'image de la figure 2.6 par l'approche FGAHL, pour un seuil de fusion de 0.4, rapporte l'image de la figure 4.9. Les régions obtenues sont représentées en assignant une couleur à chaque région segmentée.

Dans ce test, 7 échelles et 4 orientations ont été utilisées dans le filtrage de Gabor. Pour cette image, l'approche FGAHL rapporte un taux de segmentation de 98,16%. Comme pour l'image originale, la figure 4.9 est constituée de trois régions correctement segmentées, correspondants aux trois textures de l'image originale. L'approche proposée rapporte des régions homogènes et compactes. Les contours des quatre carrés sont reproduits de manière satisfaisante.



Figure 4.9. Résultat de la segmentation de l'image synthétique de la figure 2.6 en utilisant l'approche FGAHL (SA=98,16%)

Afin de montrer l'apport de l'approche FGAHL, celle-ci a été comparée avec les approches floues FCM, SFCM, et FCLIM que nous avons développées.

Les tables 4.3 et 4.4 donnent les taux de bonne segmentation comparatifs des images des figures 2.5 et 2.6 respectivement.

Table 4.3. Taux de bonne segmentation (SA) pour les différentes approches

Approches	Taux de segmentation SA (%)
FCM	87,59%
SFCM	94,32%
FLICM	97,66%
FGAHL	98,46%

Table 4.4. Taux de bonne segmentation (SA) pour les différentes approches

Approches	Taux de segmentation SA (%)
FCM	87,36%
SFCM	94,16%
FLICM	97,35%
FGAHL	98,16%

Pour les images synthétiques des figures 2.5 et 2.6, l'approche FGAHL rapporte des taux de bonne segmentation optimaux de 98,46% et 98,16% respectivement. La contribution de l'approche proposée par rapport à l'algorithme FCM est de 11,1% et 10,8%, respectivement.

4.3.2. Application aux images MSG

L'approche FGAHL a été testée sur l'image MSG de la figure 4.10. Cette image a été construite en assignant les canaux IR1.6, VIS0.8 et VIS0.6 aux composantes rouge, vert et bleue, respectivement. Dans l'image multispectrale résultante, les nuages apparaissent beige clair. Les nuages cumulus et stratocumulus couvrent une partie de l'Afrique du Nord et de l'Europe de l'ouest. La neige apparaît en bleu cyan. Les surfaces désertiques apparaissent dans les teintes roses, saumon. La végétation apparaît verte sur la combinaison colorée. Enfin, l'eau apparaît en bleu très sombre.

La figure 4.11 donne le résultat de la segmentation de l'image MSG en sept classes homogènes, pour le seuil de fusion de 0.6. Les régions obtenues sont représentées avec différentes couleurs. Dans ce test, 8 échelles et quatre orientations ont été utilisées, à savoir $\theta = 0^\circ, 45^\circ, 90^\circ, 135^\circ$. Les fréquences ont été choisies en utilisant la relation (4.6) : $\sqrt{2}\{1, 2, 4, 8, 16, 32, 64, 128\}/512$.

Le résultat de la segmentation montre que l'approche proposée rapporte une carte de segmentation compacte et cohérente, avec une reproduction assez satisfaisante des contours des régions. Les sols et les mers ont été proprement représentés. Les deux types de nuages ont été détectés et séparés. Les couleurs jaune et marron clair sont respectivement assignées aux stratocumulus et aux nuages cumulus.

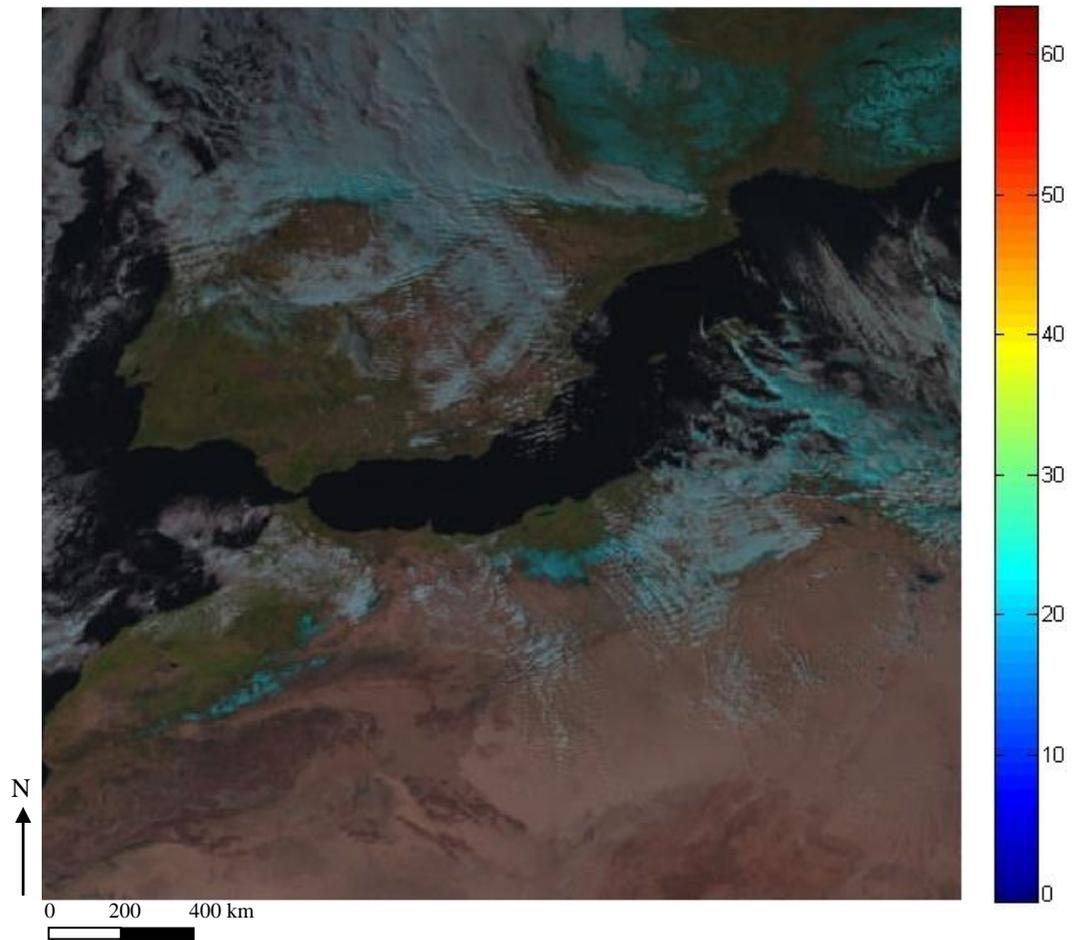


Figure 4.10. Image composite RVB, IR 1.6, VIS 0.8, VIS 0.6 acquise le 06 Février 2012 à 14:00 UTC, montrant l'Afrique du Nord, la mer the Méditerranéenne, L'Europe de l'ouest et l'Atlantique.

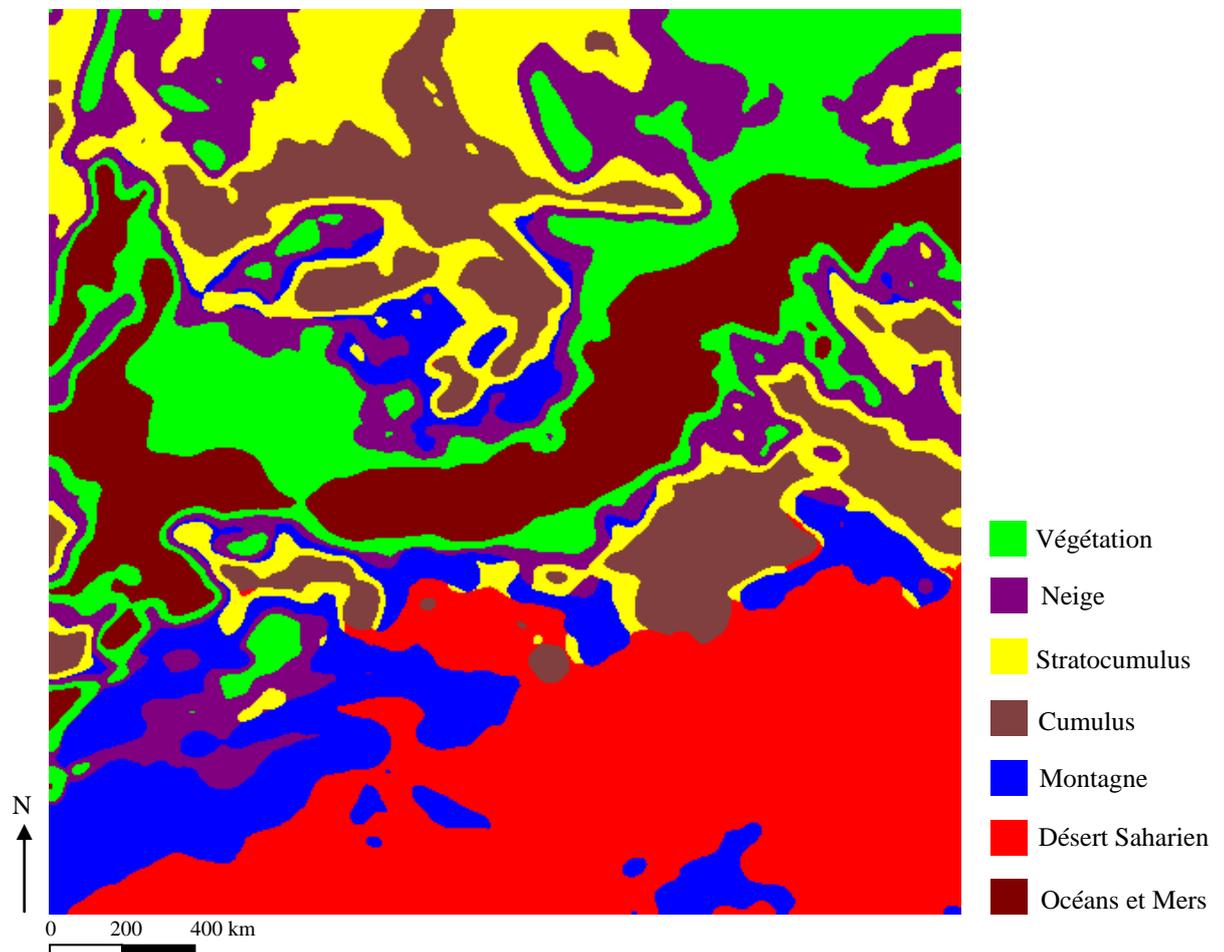


Figure 4.11. Segmentation de l'image MSG en 7 classes homogènes représentées avec différentes couleurs

4.4. Comparaison des résultats des deux approches LSF et FGAHL

Une comparaison des deux méthodes de segmentation (LSF et FGAHL) a été réalisée pour les images synthétiques et aussi les images MSG.

Les taux de segmentation obtenus sur les images synthétiques par les deux méthodes sont relativement proches. Cependant, on observe une légère supériorité de l'approche LSF. En effet, les contours des images synthétiques sont mieux reproduits par la méthode de segmentation LSF.

Les tables 4.5 et 4.6 donnent les résultats pour les images synthétiques des figures 2.5 et 2.6, respectivement.

Table 4.5. Taux de bonne segmentation (SA) pour les deux approches

Méthode	Approche LSF	Approche FGAHL
SA	98,72%	98,46%

Table 4.6. Taux de bonne segmentation (SA) pour les deux approches

Méthode	Approche LSF	Approche FGAHL
SA	98,23%	98,16%

Les figures 4.12 et 4.13 donnent les résultats de la segmentation obtenus sur l'image de la figure 2.5 par les approches LSF et FGAHL respectivement.

Les figures 4.14 et 4.15 donnent les résultats de la segmentation obtenus sur l'image de la figure 2.6 par les approches LSF et FGAHL respectivement.

Les résultats obtenus montrent que les contours des images synthétiques sont mieux reproduits par la méthode de segmentation LSF. Les images MSG montrent aussi la supériorité de l'approche LSF par rapport à l'approche FGAHL.

Les figures 4.16 et 4.17 donnent les résultats de la segmentation obtenus sur l'image multispectrale MSG par les approches LSF et FGAHL respectivement.

Les résultats montrent que les méthodes LSF et FGAHL rapportent des cartes de segmentation compactes et cohérentes. Cependant, on remarque que dans l'approche LSF, les contours sont mieux reproduits et les nuages sont mieux séparés.

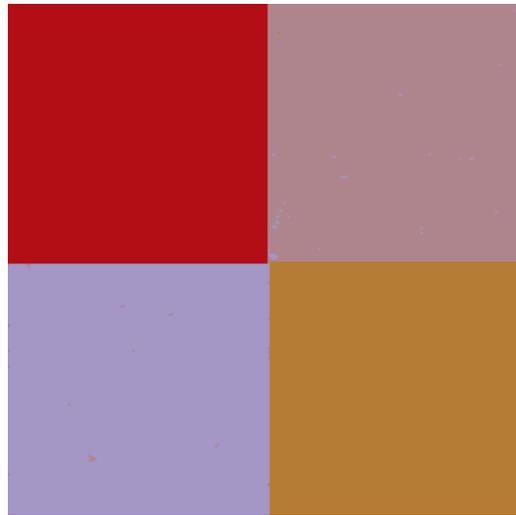


Figure 4.12 . Segmentation de l'image synthétique de la figure 2.5 en utilisant l'approche LSF
(SA=98,72%)



Figure 4.13 . Segmentation de l'image synthétique de la figure 2.5 en utilisant l'approche
FGAHL (SA=98,46%)

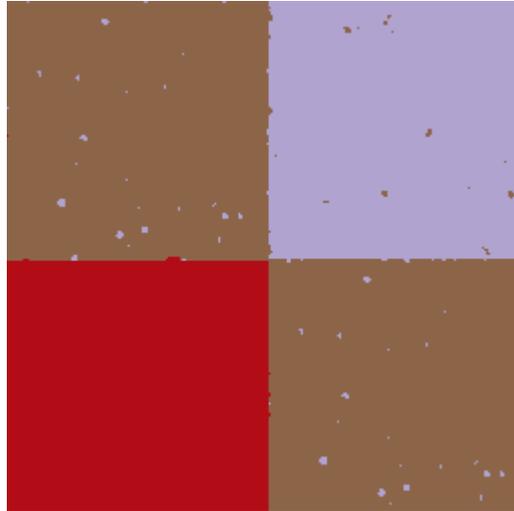


Figure 4.14 . Segmentation de l'image synthétique de la figure 2.6 en utilisant l'approche LSF
(SA=98,23%)



Figure 4.15 . Segmentation de l'image synthétique de la figure 2.6 en utilisant l'approche
FGAHL (SA=98,16%)

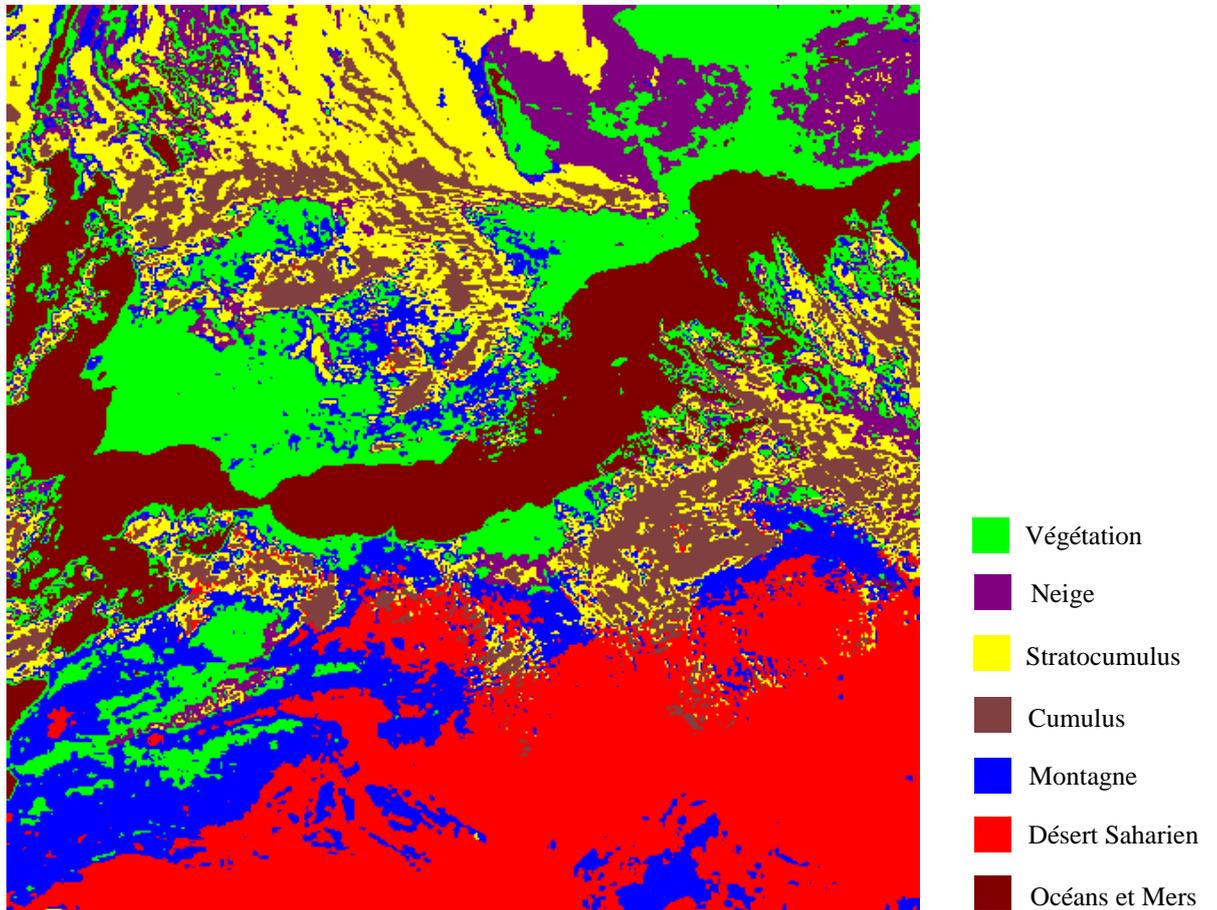


Figure 4.16 . Segmentation de l'image MSG de la figure 4.10 en utilisant l'approche LSF

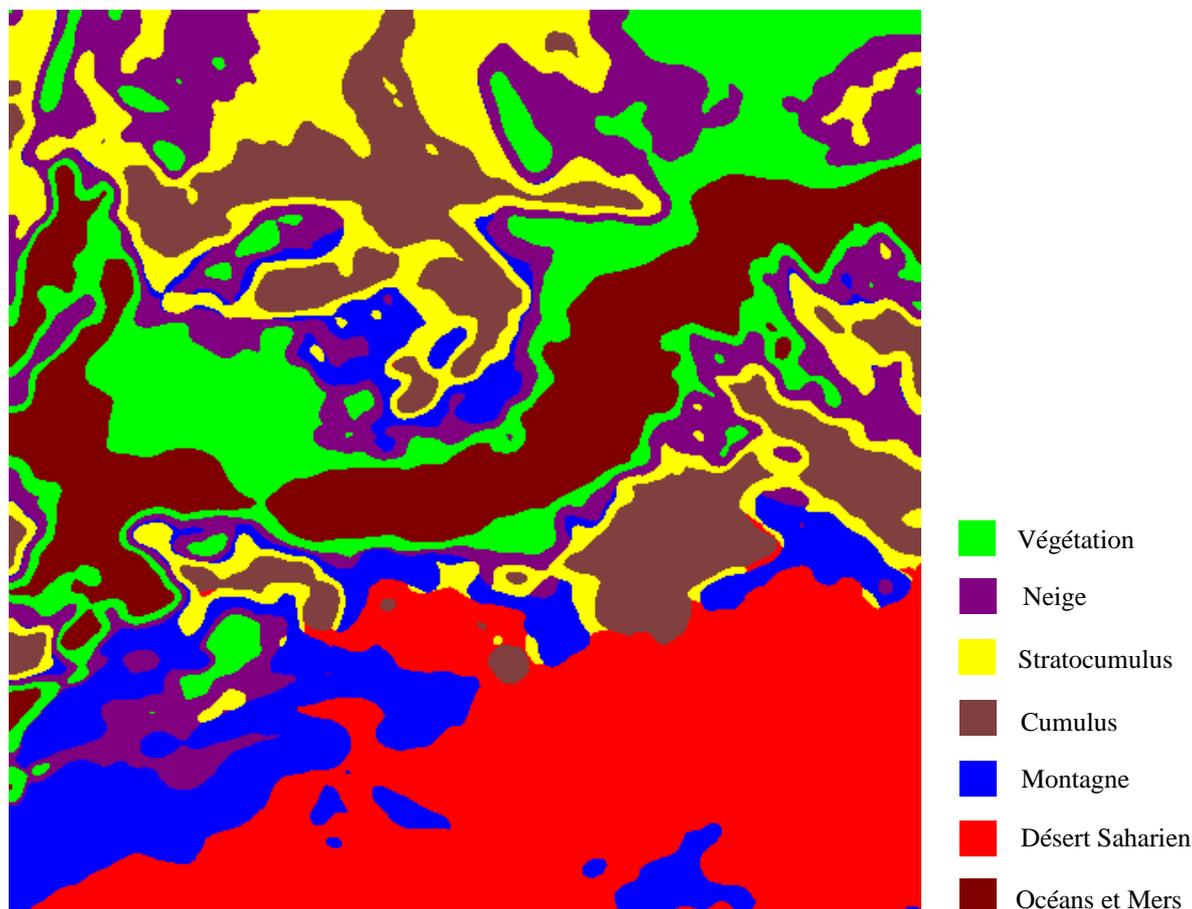


Figure 4.17. Segmentation de l'image MSG de la figure 4.10 en utilisant l'approche FGAHL

4.5. Discussion

Dans l'approche proposée, l'idée de généraliser l'analyse de la texture au domaine multispectral a été étudiée. Pour extraire les attributs de texture de l'image, le filtrage de Gabor a été appliqué aux différentes bandes de l'image. Les vecteurs attributs obtenus ont été ensuite combinés puis classés en utilisant l'algorithme de classification floue FCM. Enfin, la carte de régions obtenue a été analysée en utilisant un critère d'analyse d'homogénéité, obtenant ainsi le résultat final de la segmentation. Les résultats obtenus montrent l'apport de l'analyse de la

texture dans le domaine multispectral, où la corrélation entre les composantes de l'image est prise en compte. Les résultats montrent, aussi, la supériorité de l'approche proposée par rapport aux approches de segmentation floues SFCM et FLICM. En effet, l'approche FGAHL rapporte une carte de segmentation compacte et cohérente, avec un taux de bonne segmentation de 98,46%.

En comparant les approches de segmentations mises au point (LSF et FGAHL), on a constaté que les deux méthodes rapportent des cartes de segmentation compactes et cohérentes. Cependant, une légère supériorité de l'approche LSF a été observée. En effet, dans l'approche LSF, les contours sont mieux reproduits et les nuages sont mieux séparés.

CONCLUSION ET PERSPECTIVES

La segmentation d'images constitue une étape très importante dans l'interprétation du contenu d'une scène donnée. Dans cette thèse, nous nous sommes intéressés à la segmentation d'images multispectrales MSG. Ainsi, deux approches de segmentation ont été proposées. La première utilise une segmentation récursive basée sur la classification locale- spectrale floue et le processus de fusion des régions. La deuxième, est basée sur la classification floue des textures mutispectrale et l'analyse d'homogénéité locale.

L'objectif principal visé par ce travail est d'élaborer des stratégies de segmentation qui prennent en compte l'aspect spectral et local des images multispectrales. Les résultats obtenus par les deux techniques que nous avons élaborées montrent que l'utilisation conjointe de ces deux aspects est d'une importance majeure pour la segmentation d'images multispectrales MSG. Malgré la complexité des détails composant ces images, les différents résultats de segmentation, montrent que les images traitées ont été correctement segmentées. En effet, Pour les images test utilisées nous avons pu atteindre un taux de bonne segmentation de 98,72% avec la méthode LSF et 98,46% avec la technique FGAHL. Appliquées aux images MSG, les méthodes que nous avons élaborées ont permis de segmenter correctement les différents nuages ainsi que les différents types de sol et de mers. Les contours ont été correctement reproduits par les deux techniques, montrant ainsi la supériorité de nos méthodes comparées aux techniques usuelles publiées dans la littérature. Notons néanmoins, une légère supériorité de l'approche LSF. En effet, cette dernière reproduit plus nettement les contours et discrimine mieux les nuages.

Pour améliorer plus l'exécution de la segmentation, il serait intéressant de lancer une réflexion sur la possibilité d'une spécification automatique d'un seuil approprié, pour le processus de fusion des régions.

Annexe A

Définition des concepts fondamentaux des ensembles flous

A.1 Opérations ensemblistes : définitions originales de L. Zadeh [DOU 2006]

Dans les définitions originales de Zadeh, les opérations fondamentales possibles sur deux ensembles flous **A** et **B**, sous ensembles de X , sont l'égalité, l'inclusion, l'intersection, et la réunion,...

L'**égalité** est définie par l'égalité des fonctions d'appartenance. On a $\mathbf{A} = \mathbf{B}$, si et seulement si $\mu_{\mathbf{A}} = \mu_{\mathbf{B}}$.

L'**inclusion** d'un ensemble flou dans un autre est définie par :

$$\mathbf{A} \subseteq \mathbf{B} \Leftrightarrow \mu_{\mathbf{A}} \leq \mu_{\mathbf{B}} \quad (\text{A.1})$$

L'**intersection** $\mathbf{C} = \mathbf{A} \cap \mathbf{B}$ est définie par le minimum point à point entre les deux fonctions d'appartenance :

$$\mu_{\mathbf{C}}(x) = \min[\mu_{\mathbf{A}}(x), \mu_{\mathbf{B}}(x)], x \in X, \quad (\text{A.2})$$

Ou en forme symbolique

$$\mu_{\mathbf{C}} = \mu_{\mathbf{A}} \wedge \mu_{\mathbf{B}} \quad (\text{A.3})$$

La **réunion** $C = A \cup B$ est définie par le maximum point à point entre les fonctions d'appartenance par :

$$\mu_C(x) = \max[\mu_A(x), \mu_B(x)], \quad x \in X, \quad (\text{A.4})$$

Ou en abrégé

$$\mu_C = \mu_A \vee \mu_B \quad (\text{A.5})$$

A.2 α -cut

Tout ensemble flou peut être vu comme une famille d'ensembles flous [DOU 2006].

L' α -cut de A , notée A_α , est l'ensemble formé des éléments de X pour lesquels la fonction d'appartenance dépasse le seuil α , avec $\alpha \in [0,1]$.

L' α -cut d'un ensemble flou A est l'ensemble normal défini par

$$A_\alpha = \{x / \mu_A(x) \geq \alpha\} \quad (\text{A.6})$$

A peut être décomposé en une série de ses α -cuts,

$$A = \bigcup_{\alpha \in [0,1]} (\alpha A_\alpha) \quad (\text{A.7})$$

Annexe B

B.1 Formalisme de la logique floue [Ouattara 2009]

Désignons par X l'univers de référence composé d'éléments x . Plaçons-nous d'abord dans la théorie des ensembles classiques, c'est-à-dire nets. Tout sous-ensemble net A de X est totalement défini par sa fonction caractéristique μ_A . Cette fonction est définie sur l'ensemble d'évaluation $\{0, 1\}$ par:

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

Si l'ensemble d'évaluation est maintenant le continuum $[0,1]$, A devient un sous-ensemble flou de X , et μ_A est sa fonction d'appartenance.

Le sous-ensemble A est alors défini par :

$$A = \{[x, \mu_A(x)] \mid x \in X\} \quad (\text{B.2})$$

Le noyau A , noté $n(A)$, est l'ensemble des éléments qui appartiennent totalement à A , c'est-à-dire dont le degré d'appartenance à A vaut 1 :

$$n(A) = \{x \in X \mid \mu_A(x) = 1\} \quad (\text{B.3})$$

Le support de A, noté $s(A)$, est l'ensemble des éléments appartenant, même très peu, à A, c'est-à-dire dont le degré d'appartenance à A est différent de 0 :

$$s(A) = \{x \in X / \mu_A(x) > 0\} \quad (\text{B.4})$$

La hauteur de A, notée $h(A)$, est définie par :

$$h(A) = \sup(\mu_A(x) / x \in X) \quad (\text{B.5})$$

Une α - coupe de A est le sous-ensemble net des éléments ayant un degré d'appartenance à A supérieur ou égal à α . Il est noté $C_\alpha(A)$:

$$C_\alpha(A) = \{x \in X / \mu_A(x) \geq \alpha\} \quad (\text{B.6})$$

Le concept de relation floue est une généralisation du concept de relation d'équivalence définie dans le cas net. Une relation floue permet de mesurer, par un scalaire de l'intervalle $[0,1]$, le degré auquel une proposition logique est vérifiée. Á une relation floue R est associée une fonction d'appartenance, notée μ_R . Soient X et Y deux univers de référence, d'éléments respectifs x et y .

Une relation floue entre les éléments de ces deux univers est formellement définie par :

$$R : \begin{cases} X \times Y \rightarrow [0,1] \\ (x, y) \rightarrow \mu_R(x, y) \end{cases}$$

Lorsque $X=Y$, la relation floue est dite binaire.

B.2. Formalisme de la classification nette et de la classification floue

Dans le cadre de la théorie des ensembles nets, établir une classification nette de l'univers de référence X vers un ensemble $\Omega = \{\omega_1, \dots, \omega_{N_c}\}$ de N_c classes nettes, revient à construire une règle de décision D_n [Ouattara 2009].

Cette règle permet d'affecter tout élément x de X à un seul élément ω_i de Ω :

$$R : \begin{cases} X \rightarrow \Omega \\ x \rightarrow D_c(x) \end{cases}$$

Chaque ω_i peut être vu a posteriori comme une partie de X , et $D_n^{-1}(\Omega)$ comme une partition de X , alors, pour tout x de X :

$$\sum_{i=1}^{N_c} \mu_{\omega_i}(x) = \mu_{D_n}(x) = 1 \quad (\text{B.7})$$

L'extension au cadre des ensembles flous permet de définir une classification floue, mettant en œuvre une règle de décision D_f qui n'effectue plus un choix tranché entre l'ensemble des classes, mais qui estime le degré d'appartenance de x à chacune des classes :

$$R : \begin{cases} X \rightarrow [0, 1]^{N_c} \\ x \rightarrow D_f(x) = \{\mu_1(x), \dots, \mu_{N_c}(x)\} \end{cases}$$

$D_f^{-1}(\Omega)$ constitue une partition de X , et l'on peut écrire, pour tout x de X :

$$\sum_{i=1}^{N_c} \mu_{\omega_i}(x) = 1 \quad (\text{B.8})$$

BIBLIOGRAPHIE

M.N. Ahmed, S.M. Yamany, N. Mohamed, , A.A. Farag, T. Moriarty, “A modified fuzzy c-means algorithm for bias field estimation and segmentation of MRI data”, *IEEE transactions on medical imaging*, vol. 21, Issue 3, pp.193-199, 2002.

Z. Ameer, S. Ameer, A. Adane, H. Sauvageot, and K. Bara, “Cloud classification using the textural features of Meteosat images”, *International Journal of Remote Sensing*, Vol. 25, No. 21, pp. 4491-4503, 2004.

J. Bennett, A. Khotanzad, “Multispectral random field models for synthesis and analysis of color images”, *IEEE Transactions On Pattern Analysis And Machine Intelligence*, Vol. 20, No. 3, March 1998.

J. Bezdek, “Pattern recognition with fuzzy objective function algorithms”, *New York: Plenum*, 1981.

A. Bitam and S. Ameer, “A local-spectral fuzzy segmentation for MSG multispectral images”, *International Journal of Remote Sensing*, Vol. 34, No. 23, pp. 8360-8372, 2013.

A. Bitam, S. Ameer, “Multispectral image segmentation using Gabor filtering and local homogeneity analysis with application to MSG”, *Proceedings of the 3th International Conference on Systems and Control (ICSC'13)*, 29-31 October 2013, Algiers, Algeria.

C. Bouman, M. Shapiro, “Multispectral image segmentation using a multiscale modele”, *IEEE international conference on acoustics, speech, and signal processing*, vol. 3, pp. 565-568, 23-26 march, 2003.

W. Cai, S. Chen, and D. Zhang, “Fast and robust fuzzy c-means clustering algorithms incorporating local information for image segmentation”, *Pattern Recognition*, 40, (3), pp. 825-838, 2007.

T.F. Chan, B. Y. Sandberg, L.A.Vese, “Active contours without edges for vector-valued images”, *Journal of Visual communication and image representation*, 11, pp. 130-141, 2000.

C. F. Chen, “ Segmentation of high resolution satellite imagery using texture and spectral information”, *Geoscience and remote sensing symposium*, vol. 4, pp. 1859-1861, 1993.

S. Chen, D. Zhang, “Robust image segmentation using FCM with spatial Constraints based on new Kernel – induced distance measure”, *IEEE transactions on systems, Man, and cybernetics*, vol. 34, no. 4, august 2004.

H.D.Cheng, and Y. Sun, “A hierarchical approach to color image segmentation using homogeneity”, *IEEE Transactions on Image Processing*, vol. 9, Issue 12, pp. 2071–2082, 2000.

K.S. Chuang, H.L. Tzeng, S. Chen, J. Wu, and T.J. Chen, “Fuzzy c-means clustering with spatial information for image segmentation”, *Computerized Medical Imaging and Graphics*, 30, pp. 9-15, 2006.

Comprendre la météo. <http://www.comprendre.meteofrance.com>.

P. Colantini, B. Laget, “Color image segmentation using region adjacency graphs”, *IEEE transaction on image processing*, vol. 9, issue: 4, Apr. 2000.

C. Collet, M. Louys, A. Oberto, C. Bot, “Markov model for multispectral image analysis: Application to small megellanic cloud segmentation”, *International conference on image processing*, 2003.

Colombia-Utrecht Reflectance and texture Database.

<http://www1.cs.colombia.edu/cave/exclude/curet/datacomp>.

Compositions colorées. <http://epi.univ-paris1.fr>.

Q. Cunyong, X. Jian, Y. Long, H. Lu, “An interval type-2 fuzzy c-means algorithm based on spatial information for image segmentation”, *Eight International Conference on Fuzzy Systems and knowledge Discovery (FSKD)*, vol. 1, pp. 545-549, 2011.

M.J. Daily, “color image segmentation using markov random fields”, IEEE international conference on computer vision and pattern recognition, pp. 304-312, 4-8 June 1989.

Y.N. Deng, B.S. Manjunath, Unsupervised Segmentation of color-texture Regions in Images and video, IEEE transaction on PAMI, vol. 23 , No. 8, pp. 800-810, 2001.

J. C. Devaux, P. Gouton , F. Truchetet , “Aerial colour image segmentation by Karhunen-Loeve transform”, Proceedings of 15th International Conference on Pattern Recognition, vol. 1, pp. 309 – 312, Barcelona, 3-7 Sept., 2000.

P. Dong-Chul, “Intuitive Fuzzy c-means algorithm for MRI segmentation”, International Conference on Information Science and Applications (ICISA), pp. 1-7, 2010.

L.S. Dooley, G.C. Karmakar, M. Murshed, “A fuzzy rule-based colour image segmentation algorithm”, International Conference on Image Processing, vol. 1, pp. 977-980, 14-17 September 2003.

W. DOU, “Segmentation d’images multispectrales basée sur la fusion d’informations: application aux images IRM”, these de doctorat en traitement du signal et des images, université de Caen, 2006.

J. Dunn, A fuzzy relative of the ISODATA process and its use in detecting compact well separated clusters, *J. Cybern.*, vol. 3, pp. 32–57, 1974.

E-cours. <http://e-cours.univ-paris1.fr>.

Eumetsat, 2005, MSG: Meteosat Second Génération En Orbit - En Service. http://www.eumetsat.int/groups/cps/documents/document/pdf_br_msg02_fr.pdf.

Z. Feng, J. Licheng, “Spatial improved fuzzy C-means clustering for image segmentation”, International conference on Electronic and mechanical engineering and information technology (EMEIT), vol. 9, pp. 4791-4794, 2011.

M.F. A. Fortier, D. Ziou, C. Armenakis, S. Xang, “Nouvelles perspectives en detection de contours: textures et images multispectrales”, vision interface, trios rivière, 19-21 may. 1999.

I. Gath, and A.B. Geva, Unsupervised optimal fuzzy clustering, *IEEE transaction on pattern analysis and machine intelligence*, vol. 11, Issue 7, pp. 773-780, 1989.

M. Gordan, C. Kotropoulos, A. Georgakis, I. Pitas, “A new fuzzy c-means based segmentation strategy; Applications to lip region identification”, IEEE-TTTC International Conference on Automation, Quality and Testing, Robotic, Cluj-Napoca, Romania, May 23-25, 2002.

C. Gruia, F. Pop, V. Cristea, “A distributed algorithm for multispectral image segmentation”, Ninth international symposium on symbolic and numeric algorithms for science computing, pp. 353-360, 26-29 September 2007.

J.F. Haddon, J.F.Boyce, “Co-occurrence matrices for image analysis”, *Electronics & Communication Engineering Journal* April 1993.

R.J. Hathaway, J.C. Bezdek, “Fuzzy c-means clustering of incomplete data”, *IEEE transactions on Systems, Man, and Cybernetics, Part B: Cybernetics*, vol. 31, Issue 5, pp.735-744, 2001.

C. Heng-Da, S. Ying, “A hierarchical approach to color image segmentation using homogeneity”, *IEEE Transactions on Image Processing*, vol. 9, Issue 12 , pp. 2071 – 2082, 2000.

O.J. Hernandez, A. Khotanzad, “color image segmentation using multispectral random field texture model & color content features”, *pattern recognition*, volume 36, issue 8, pp: 1679-1694, august 2003.

V. L. Huynh, K. Jong-Myon, “A generalized spatial fuzzy c-means algorithm for medical image segmentation”, *IEEE International Conference on Fuzzy Systems*, pp. 409 – 414, 2009.

N. Ikonomakis, K.N. Pataniotis, A.N. Venetsanopoulos, “Unsupervised seed determination for a region– based color image segmentation scheme”, *Proceedings of the International Conference on Image Processing*, vol. 1, pp. 537–540, Vancouver, BC, 10-13 Sept. 2000.

A. K. Jain, F. Farrokhinia, “Unsupervised texture segmentation using Gabor filters”, *Pattern Recognition*, vol. 24, no. 12, pp. 1167-1186, 1991.

A.K. Jain, M.N. Murty, and P.J. Flynn, 1999, Data clustering: a review, *ACM computing surveys*, vol. 31, No. 3, pp. 265-323, September 1999.

F. Jing, M. Li, H. Jiang Zhang, B. Zhang, “Unsupervised image segmentation using local homogeneity analysis”, *IEEE International Symposium on Circuits and Systems*, vol. 2, pp. 456–459, 25-28 may 2003.

S.R. Kannan, R. Pandiyarajan, S. Ramathilagam, “Effective weighted bias fuzzy c-means in segmentation of brain MRI”, *International Conference on Intelligent and Advanced Systems (ICIAS)*, pp.1-6, 2010.

Z. Kato, T.C. Pong, “A markov random field image segmentation model for color textured images”, *Image and Vision Computing*, 24, pp. 1103-1114, 2006.

A. Khotanzad, O.J. Hernandez, “ Color image retrieval using multispectral random field texture models”, *pattern recognition*, volume 36, issue : 8, pp. 1679-1694, August 2003.

S. Krinidis and V. Chatzis, “A robust fuzzy local information c-means clustering algorithm”, *IEEE transactions on image processing*, vol. 19, No. 5, May 2010.

F. Kurugollu, B. Sankur, A. E. Harmanci, “Color image segmentation using histogram multithresholding and fusion”, *Image and Vision Computing*, vol. 19, Issue 13, pp. 915-928, 2001.

N.M. Kwok, Q.P. Ha, G. Fang, “Effect of color space on color image segmentation” 2nd *International Congress on Image and Signal Processing (CISP)*, pp. 1-5, 2009.

E. Kyoung-Bae, L. Joonwhoan, A.N. Venetsanopoulos, “Color image segmentation using a possibilistic approach”, *IEEE International Conference on Systems, Man, and Cybernetics*, pp. 1150-1155, 1996.

P. Lambert, “ Etude méthodologiques du filtrage et de la segmentation d’images multi-composantes”, *Habilitation à diriger des recherché en Electronique, Electrotechnique et Automatique*, Université De Savoie, 2002.

P. Lanchantin, F. Salzenstein, "Segmentation d'images multispectrales par arbre de markov cache flou", actes de colloques, GRETSI 2005.

La télédétection spatiale. <http://bictel.ulg.ac.be>

C. P. Lee, W. Snyder, C. Wang, "Supervised multispectral image segmentation using active contours", IEEE International conference on robotics and automation, pp. 4242-4247, Barcelona, Spain, April, 2005.

C. Li, C. Xu, C. Gui, M.D. Fox, "Level set evolution without re-initialization : A new variational formulation", IEEE computer society conference on computer vision and pattern recognition, 2005.

Z. Liang, D. Wang, J. Ye, D. Harrington, " Development of Automatic Techniques for Segmentation of Brain Tissues from Multispectral MR Images", IEEE conference on nuclear science and medical imaging", vol. 3, pp. 1453-1456, Nov. 2003.

X. LIU, "Analyse d'images couleur en composantes independantes par reseau de neurones", These de doctorat en signal, image, parole, institut national polytechnique, université de grenoble, 1991.

S. Livens, P. Scheunders, G. Van de Wouwer, D. Van Dyck, "Wavelets for texture analysis, an overview", IPA 97, pp. 581-585, 15-17 July 1997.

L. Lucchese, S.K. Mitra, "Advances in color image segmentation" Global Telecommunications Conference, Vol. 4, pp: 2038-2044, 1999.

A. Lundervold, G. Storvik, " Segmentation of Brain Parenchyma and Cerebrospinal Fluid in Multispectral Magnetic Resonance Images", IEEE Transactions On Medical Imaging, Vol. 14, No. 2, June 1995.

J. Luo, R.T. Gray, H.C. Lee. "Incorporation of derivative priors in adaptive Bayesian color imags segmentation", IEEE International conference on image processing, 1998.

S. Makrogiannis, G. Economou, S. Fotopoulos, N.G. Bourbakis, "Color image segmentation using multiscale fuzzy c-means and graph theoretic merging", *IEEE Transactions on Systems, Man and Cybernetics, Part A: Systems and Humans*, vol.35, Issue 2, pp. 224-238, 2005.

B. S. Manjunath, W.Y. Ma, "Texture features for Browsing and Retrieval of Image Data", *IEEE transactions on pattern analysis and machine intelligence*, vol. 18, No. 8, August 1996.

K. V. Mardia, T.J. Hainsworth, "A spatial thresholding method fo image segmentation", *IEEE Transactions On Pattern Analysis And Machine Intelligence*, Vol. 10, No. 6, November 1988.

A. Martinez- Uso, F. Plat, P. Garcia-sevilla, "Multispectral image segmentation by energy minimization for fruit quality estimation", *pattern recognition and image analysis*, volume 3523, pp: 689-696, 2005.

I. Michaud, "Application de l'algorithmme EM au modèle des risques concurrents avec causes de panne masquées", Mémoire présenté à la Faculté des études supérieures de l'Université Laval dans le cadre du programme de maîtrise en statistique pour l'obtention du grade de maître ès sciences, faculté des sciences et de génie, université Laval, Québec, Aout 2005.

P. Mitra, B.U. Shankar, S.K. Pal, "Segmentation of multispectral remote sensing images using active support vector machines". *Pattern Recongnition Letters* 25, pp. 1067-1074, 2003.

M. Moghrani, "Segmentation coopérative et adaptative d'images multicomposantes: Application aux images CASI". Phd thesis, Université de Rennes 1, 2007.

F. Murtagh, A.E. Raftery, J.L. Starck, "Bayesian inference for multiband image segmentation via model-based cluster trees", *image and vision computing* 23, pp: 587-596, 2005.

J.C. Noordam, W.H.A.M. Van Den Brook, L.M.C. Buydens, "Geometrically guided fuzzy C-means clustering for multivariate image segmentation", *Proceeding of International Conference on Pattern Recongnition*, pp.462-465, 2000.

D. Nuzillard, C. Lazar, "Partitional Clustering Techniques for multispectral image segmentation", *Journal of Computers*, vol. 2, no. 10, December 2007.

G. Ons, R. Tebourbi, "Object oriented hierarchical classification of high resolution remote sensing images", 16th IEEE International Conference on Image Processing (ICIP), pp. 1681-1684, 2009.

S. Ouattara, "Stratégies de segmentation d'images multicomposantes par analyse d'histogrammes multidimensionnels. Application à des images couleur de coupes histologiques de pommes", Thèse de doctorat en traitement du signal et des images, Université d'angers, 2009.

N.R. Pal, J.C. Bezdek, "On cluster validity for the fuzzy c-means model", IEEE transaction on fuzzy systems, vol. 3, Issue 3, pp. 370-379, 1995.

W. Pedrycz, J. Waletzky, "Fuzzy clustering with partial supervision", IEEE transactions on systems, Man, and Cybernetics, Part B: cybernetics, vol. 27, Issue 5, October 1997.

D. L. Pham, "Fuzzy clustering with spatial constraints", IEEE international conference on image processing, 2002.

D. L. Pham, "Adaptive fuzzy segmentation of Magnetic Resonance Images", IEEE Transactions On medical imaging, Vol. 18, No. 9, September 1999.

L. P. Podenok, R.K. Sadykhov, "Multispectral satellite image segmentation using fuzzy clustering and nonlinear filtering methods", IEEE International conference on Machine vision and Image processing", pp.43-48, 2008.

Y. Qixiang, G. Wen, Z. Wei, "Color image segmentation using density-based clustering", International Conference on Multimedia and Expo, Vol. 2, pp. 401-404, 6-9 July 2003.

M. A. Roula, A. Bouridane, F. Kurugollo, A. Amira, "Unsupervised segmentation of multispectral images using edge progression and cost function", IEEE international conference of image processing, vol. 3, pp: 781-784, 24-28 juin 2002.

M. Rousson, R. Deriche, "A variational framework for active and adaptative segmentation of vector valued images", IEEE proceeding of the workshop on motion and video computing, 2002.

K. Saarinen , “Color image segmentation by a watershed algorithm and region adjacency graph processing”, IEEE International Conference on Image Processing, Vol. 3, *pp.* 1021–1025, Austin, TX., USA, 13-16 November, 1994.

F. Salzenstein, C. Collet, M. Petremand, “ Champs de markov flous pour images multispectrales”, *traitement du signal*, volume 21, no. 1, 2004.

W. R. Schwartz, H. Pedrini, “Color Textured Image Segmentation Based on Spatial Dependence using 3D Co-occurrence Matrices and Markov Random Fields”, 15th International Conference in Central Europe on Computer Graphics, Visualization and Computer Vision, Plzen, Czech Republic, *pp.* 81-87, 2007.

A. Selb, H. Bischof, A. Leonardis, “Fuzzy c-means in a MDL framework”, Proceedings of 15th International Conference on Pattern Recognition, vol.2, *pp.* 740-743, 2000.

Z. Song, N. Tustison, B. Avants, J. Gee, “Adaptive graph cuts with tissue priors for brain MRI segmentation”, 3rd international symposium on biomedical imaging, *pp.* 762-765, 6-9 April 2006.

N. Thanh, R. Wehrens, M.C. Buydens Lutgarde, “Knn Density-Based Clustering for High Dimensional Multispectral Images”, Joint workshop on fusion over Urban Areas, *pp.* 147-151, 22-23 May 2003.

J. Theiler, G. Gisler, “A contiguity-enhanced k-means clustering algorithm for unsupervised multispectral image segmentation”, Proceedings of International Society for Optical Engineering (SPIE), *pp.* 108-118, 1997.

P. Thitimajshima, “A New Modified Fuzzy C-Means Algorithm for Multispectral Satellite Images Segmentation”, IEEE international symposium on Geoscience and remote sensing, vol. 4, *pp.* 1684-1686, July 2000.

S. Tominaga, “Region Segmentation by Multispectral Imaging”, IEEE symposium on image analysis and interpretation, *pp.* 238-242, April 2002.

A. Tremeau, P. Colantoni, “Regions adjacency graph applied to color image segmentation”, IEEE Transactions on Image Processing, vol. 9, no. 4, pp. 735-74, 2000.

L. W. Tsai, D.C. Tseng, “Segmentation of multispectral remote sensing images based on Markov random fields”, IEEE international conference on Geoscience and remote sensing, vol. 1, pp. 264-266, August 1997.

D.C. Tseng, C.H. Chang, “Color segmentation using perceptual attributes” Pattern Recognition, 11th International Conference on Image, Speech and Signal Analysis Vol. 3, pp. 228 – 231, 30 August -3 September 1992.

D.C Tseng, Y.F. Li, C.T. Tung, “Circular histogram thresholding for color image segmentation”, Third International Conference on Document Analysis and Recognition vol. 2, pp. 673 – 676, 14-16 August 1995.

N. Vandenbroucke, “Segmentation d’images couleur par classification de pixels dans des espaces d’attributs colorimétriques adaptés” Thèse de Doctorat, en Automatique et Informatique Industrielle, Université de LILLE 1, 2000.

N. Voisine, “Approche adaptative de coopération hiérarchique de méthodes de segmentation”, application aux images multicomposantes. Phd thesis, Université de Rennes 1, 2002.

H. Wang and D. Suter, “Color image segmentation using global information and local homogeneity”, proceeding of the seventh conference on Digital Image Computing: Techniques and Applications, pp. 89-98, 10-12 Dec. 2003, Sydney.

Z.Wei, C.Li, Z.Yu-zhu, “A new hybrid algorithm for image segmentation based on rough sets and enhanced fuzzy c-means clustering”, IEEE International Conference on Automation and logistics (ICAL), pp. 1212-1216, 2009.

S. Wesolkowski, P. Fieguth, “Adaptive color image segmentation using markov random fields”, IEEE international conference on image processing, vol. 3, pp: 769-772, 24-28, June 2002.

- S. Wesolkowski, P. Fieguth, “Color image segmentation using connected regions”, 2003. IEEE Canadian Conference on Electrical and Computer Engineering, Vol. 2, pp. 1203 – 1206, 4-7 May 2003.
- S. Wesolkowski, P. Fieguth, “A markov random fields model for hybrid edge- and region-based color image segmentation”, IEEE conference on Electrical and computer engineering, vol. 2, pp. 945-949, Canada, 2002.
- D. Xu, “Segmentation of multi-channel image with markov random field based active contour model”, journal of VLSI signal processing 31, 45-55, 2002.
- H. Xue, T. Géraud, A.Duret-Lutz, “Multi-band segmentation using morphological clustering and fusion- application to color image segmentation”, IEEE international conference on image processing, 2003.
- T. Yamazaki, and D. Gingras, 1995, Image classification using spectral and spatial information based on MRF models. *IEEE Transactions on Image Processing*, Vol. 4, No. 9, pp. 1333-1339.
- Q. Ye, W. Gao, W. Zeng, “ Color image segmentation using density-based clustering”, IEEE international conference on acoustics, speech & signal processing, april 6-10, hong-kong.
- V. M. Yeddid, S. Tilie, J. C. Olivio-marin, “color image segmentation based on markov random field clustering for histological image analysis”,16th IEEE international conference on pattern recognition, pp. 796-799, 2002.
- Z. Yong, X. Naixue, R. He, “A two stage image segmentation method based on watershed and fuzzy c-means”, IEEE Conference on Asia-Pacific Services Computing pp. 1550-1555, 2008.
- Lotfi A. Zadeh, “Fuzzy sets”, Information and controls, vol. 8, No. 3, pp. 338-353, 1965.
- J. Zhang, T. Tan, L. Ma, “Invariant texture segmentation via circular Gabor filter”, Proceedings of the 16th International Conference on Pattern Recognition (ICPR), Vol. 2, pp. 901-904, 2002.
- S. C. Zhu, A. Yuille, “Region competition: unifying snakes, region growing, and bayes/MDL for multiband image segmentation”, IEEE transaction on pattern analysis and machine intelligence, vol. 18, No. 9, September 1996.

Résumé

Dans cette thèse, nous présentons deux méthodes de segmentation d'images satellitaires météorologiques de type MSG. La majorité des méthodes de segmentation développées jusqu'à présent sont destinées aux images en niveaux de gris. Des travaux récents, ont été consacrés pour généraliser celles-ci aux images multispectrales. Cependant, ces approches utilisent généralement des stratégies de segmentation qui ne prennent pas en compte les corrélations spectrales et spatiales existantes entre les pixels de l'image. Pour palier cet inconvénient, nous avons élaboré deux techniques de segmentation qui permettent de détecter les régions d'intérêt dans des images multispectrales. La première, utilise une segmentation récursive locale-spectrale floue (LSF) qui réduit dynamiquement le nombre de classes. La deuxième est basée sur la classification floue des textures multispectrales et l'analyse d'homogénéité locale (FGAHL). Appliquées à des images synthétiques texturées couleur, les deux méthodes développées (LSF et FGAHL), rapportent des cartes de segmentation compactes et cohérentes. Les taux de bonne segmentation obtenus pour les images synthétiques sont de 98,72% et 98,46% respectivement.

Concernant les images MSG, les différents nuages ainsi que les différents types de sol et de mers ont été correctement détectés et identifiés et les contours ont été correctement reproduits par les deux techniques. Notons néanmoins une légère supériorité de l'approche LSF. En effet, cette dernière reproduit plus nettement les contours et discrimine mieux les nuages.

Mots-clés: Segmentation locale-spectrale floue, segmentation récursive, analyse d'homogénéité locale, textures spectrales, classification floue des textures multispectrales, images multispectrales MSG.

Abstract

In this thesis, we present two methods of segmentation of weather satellite images of type MSG. The majority of the methods of segmentation developed until now are intended for the images in levels of gray. Recent work was devoted to generalize the existing methods with the case of multispectral images. However, these approaches generally use strategies of segmentation which do not take into account the spectral and space correlations existing between the pixels of the image. To answer this disadvantage, we worked out two techniques of segmentation which make it possible to detect the areas of interest in multispectral images. The first uses local-spectral fuzzy recursive segmentation (LSF) which reduces the number of classes dynamically. The second is based on the classification of the multispectral textures and the analysis of local homogeneity (FGAHL). Applied to colour textured synthetic images, the two developed methods (LSF and FGAHL) yield compact and coherent segmentation maps. The rates of good segmentation obtained for the synthetic images are 98,72% and 98,46% respectively.

Concerning the MSG images, the various clouds as well as the various types of ground and seas were correctly detected and identified and contours were correctly reproduced by the two techniques. We note nevertheless a light superiority of the LSF approach. Indeed, the latter reproduces contours more clearly and discriminates the clouds better.

Keywords: Local-spectral fuzzy segmentation, recursive segmentation, local homogeneity analysis, spectral textures, fuzzy classification of multispectral textures, MSG multispectral images.