

**MINISTERE DE L'ENSEIGNEMENT SUPERIEUR ET DE LA RECHERCHE SCIENTIFIQUE
UNIVERSITE MOULOU MAMMERI, TIZI - OUZOU**

**FACULTE DE GENIE ELECTRIQUE ET D'INFORMATIQUE
DEPARTEMENT : ELECTRONIQUE**

Thèse de doctorat

SPECIALITE : Electronique

Option : Télédétection

Présentée par : SEHAD Mounir

Titre :

**Segmentation d'images par une approche basée sur des caractéristiques
texturales, temporelles et spectrales : Application aux images MSG**

Devant le jury d'examen composé de :

Mr. DJEDDI Mabrouk	Professeur à l'UMBB	Président
Mr. AMEUR Soltane	Professeur à l'UMMTO	Rapporteur
Mr. BOUTARFA Abdelhalim	Professeur à l'Université de Batna	Examineur
Mme. HADJ SAID Naima	Professeur à l'USTO	Examinatrice
Mme. AMEUR Zohra	Professeur à l'UMMTO	Examinatrice
Mr. HADDAB Salah	Maître de conférences (A) à l'UMMTO	Examineur

Remerciements

Le travail présenté dans cette thèse a été réalisé au laboratoire LAMPA (Laboratoire d'Analyse et de Modélisation des Phénomènes Aléatoires) de l'Université Mouloud MAMMERI de Tizi-Ouzou, Algérie.

Mes plus vifs remerciements s'adressent à mon directeur de thèse, le Professeur Soltane AMEUR, qui a su me lancer dans un domaine passionnant. Il n'a jamais ménagé son temps ni ses efforts pour m'accompagner tout au long de ce travail. Ses enseignements et sa confiance m'ont permis de m'épanouir scientifiquement pendant ces années.

Je souhaite exprimer ma reconnaissance et ma gratitude toute particulière à Monsieur DJEDDI Mabrouk Professeur à l'UMBB, qui a accepté de présider mon Jury.

J'adresse mes sincères remerciements à Monsieur Abdelhalim BOUTARFA, Professeur à l'Université de Batna d'avoir accepté de faire partie de mon Jury.

Je suis reconnaissant à Madame Zohra AMEUR, Professeur à l'UMMTO et Directrice du laboratoire de recherche LAMPA, pour ses précieux conseils et d'avoir mis à ma disposition les moyens nécessaires pour réaliser mon travail dans de bonnes conditions. Aussi, je la remercie pour avoir accepté de participer au Jury.

J'adresse mes sincères remerciements à Madame HADJ SAID Naima, Professeur à l'USTO de m'avoir fait l'honneur de faire partie du jury.

Je tiens à remercier Monsieur HADDAB Salah, Maître de conférences à l'UMMTO pour avoir accepté d'évaluer mon travail.

Mes plus chaleureux remerciements vont à ma très chère famille ainsi qu'à mes amis, plus particulièrement Lazri Mourad, Ouallouche Fethi, Mohia Yacine et Hameg Slimane.

Résumé

Le but de notre travail est l'élaboration d'une méthode d'identification par satellite des régions précipitantes et de classification des nuages précipitants en deux classes principales : nuages convectifs et nuages stratiformes. Notre approche est basée sur des caractéristiques spectrales, texturales et temporelles des nuages précipitants. Les paramètres utilisés dans notre méthode correspondent à la structure microphysique et optique des nuages : épaisseur optique des nuages, rayon effectif des particules dans les nuages ainsi que la phase des nuages (glace ou liquide). Le paramètre de texture est calculé à partir de la méthode des vecteurs de rang, et le paramètre temporel correspond au taux de variation de la température du sommet des nuages entre deux images consécutives.

Par ailleurs, la classification des nuages précipitants en convectifs et stratiformes a été réalisée avec deux réseaux de neurones multicouches MLP-D pour le jour et MLP-N pour la nuit. L'apprentissage de ces deux réseaux a été effectué en utilisant une base de données constituée d'images satellite MSG et Radar prises dans la région de Sétif au nord de l'Algérie durant la période de Novembre 2006 à Mars 2007. L'évaluation de notre approche a été réalisée avec des images prises durant la période de Novembre 2010 à Mars 2011.

Les résultats obtenus par notre méthode ont été comparés avec les données radar et avec les résultats de la méthode de référence ECST (Enhanced Convective Stratiform Technique) qui est basée uniquement sur l'infrarouge. Les résultats montrent une bonne identification et classification des nuages précipitants pendant le jour et la nuit. En effet, pour l'identification, les probabilités de détection et de fausse détection sont : $[(POD_Y=82\%, POFD_Y=1\%)]$ pour le jour et $[(POD_Y=78\%, POFD_Y=2\%)]$ pour la nuit, et pour la classification des nuages convectifs : $[(POD_C=82\%, POFD_C=16\%)]$ pour le jour et $[(POD_C=79\%, POFD_C=18\%)]$ pour la nuit.

Mots clés: Identification, classification, réseaux de neurones, nuages précipitants, MSG, Radar.

Abstract

The aim of this work is to develop a new scheme for identification and classification of rainfall areas in convective and stratiform rain using meteorological satellite data. The technique is based on spectral, temporal and textural properties of clouds. The introduced classification method uses as spectral parameters the optical thickness, effective droplet radius and the cloud phase (Ice, water). The textural information is based on the grey level rank approach. The temporal parameter is the rate of change of brightness temperature over two consecutive images.

Moreover, the developed daytime and nighttime rain area classification technique is based on two multilayer perceptron neural networks (MLP-D for daytime and MLP-N for nighttime). The two MLP (MLP-D and MLP-N) were trained using SEVIRI data set over north Algeria for precipitation scenes from November 2006 to March 2007 and the models are validated against independent precipitation scenes during November 2010 to March 2011 which are not used for training the rain area delineation algorithms.

The results of the developed scheme were compared with both corresponding ground based radar and ECST algorithm. The validation scores have shown the outperformance of the developed method during the daytime and nighttime for the identification of the raining clouds, as well for the classification of the rainy areas into convective and stratiform regions. Indeed, the probabilities of detection are: $[(POD_Y=82\%, POFD_Y=1\%)]$ for daytime and $[(POD_Y=78\%, POFD_Y=2\%)]$ for nighttime, and for the convective cloud classification: $[(POD_C=82\%, POFD_C=16\%)]$ for daytime and $[(POD_C=79\%, POFD_C=18\%)]$ for nighttime.

Keywords: Identification, classification, neural networks, raining clouds, MSG, Radar.

Acronymes

AVHRR: Advanced Very High Resolution Radiometer

BT : Brightness Temperature / Température de Brilliance

CSI : Critical Success Index

CST : Convective Stratiform Technique

CTT: Cloud Top Temperature

CWP: Cloud Water Path

ECST: Enhanced Convective Stratiform Technique

FAR: False Alarm Ratio

FOV: Field of View

GFOV: Ground Field of View

GOES: Geostationary Operational Environmental Satellite

IR: Infrared

IWC: Ice Water Content

IWP: Ice Water Path

LWC: Liquid Water Content

LWP: Liquid Water Path

MLP: Multilayer perceptron

MODIS: Moderate Resolution Imaging Spectroradiometer

MSG: Meteosat Second Generation

NIR: Near Infrared

NOAA: National Oceanic and Atmospheric Administration

OMM : Organisation Mondiale de la Météorologie

ONM : Office National de Météorologique

POD : Probability Of Detection

POFD: Probability Of False Detection

PR: Precipitation Radar

RACT-DN: Rain Area Classification Technique during Daytime and Nighttime (RACT-DN)

SEVIRI: Spinning Enhanced Visible and Infra Red Imager

TRMM: Tropical Rainfall Measuring Mission

VIS: Visible

WV: Water Vapor

SOMMAIRE

INTRODUCTION	1
---------------------------	----------

Chapitre 1 : Nuages et précipitations

1.1 Préambule	5
1.2 Caractéristiques et classification des nuages	6
1.2.1. Définition	6
1.2.2. Classification des nuages	6
1.3 Formation des nuages.....	6
1.3.1. Condition nécessaire à la formation d'un nuage.....	6
1.3.2. Formation de gouttelettes nuageuses à partir de la vapeur d'eau.....	9
1.3.3. Formation des cristaux de glace	9
1.4 Des hydrométéores nuageux aux précipitations.....	10
1.4.1. Précipitations liquides.....	10
1.4.2. Précipitations solides	10
1.5 Précipitations stratiformes ou convectives	11
1.6 Précipitations stratiformes et convectives	12
1.7 Propriétés radiatives des précipitations et des nuages	12
1.8 Discussion.....	14

Chapitre 2 : Dispositifs d'Imagerie Satellitaire et Radar en Météorologie

2.1 Préambule.....	15
2.2 Principe de la télédétection	15
2.3 L'observation spatiale.....	18
2.3.1 Principe de fonctionnement d'un capteur optique	18
2.3.2 Caractéristiques des images	20
2.4 Satellites météorologiques.....	20
2.4.1 Les satellites géostationnaires.....	21
2.4.2 Les satellites polaires.....	22
2.5 Le satellite METEOSAT.....	23
2.5.1 METEOSAT de première génération.....	23
2.5.2 Le satellite METEOSAT seconde génération.....	26
2.5.2.1 Les canaux visibles.....	27
2.5.2.2 Les canaux vapeur d'eau.....	28
2.5.2.3 Les canaux infrarouges	28
2.6. Le radar météorologique.....	32
2.6.1. Principe du radar à impulsions.....	32
2.6.2 L'équation du radar pour la mesure des précipitations.....	33
2.6.3 Modèles de diffusion - Facteurs de réflectivité radar.....	34
2.6.4 Influence de la longueur d'onde sur les mesures radar.....	36
2.6.5 Atténuation des ondes électromagnétiques par les hydrométéores.....	36
2.6.6 Atténuation des ondes électromagnétiques par la pluie.....	37
2.7. Conclusion.....	38

Chapitre 3 : Méthodes de Segmentation et de classification des images satellitaires

3.1 Préambule.....	39
3.2 Stratégie de segmentation des images multispectrales.....	40
3.3 Approches de segmentation d'images.....	40
3.1.1 Approches contours	40
3.1.2 Approches régions.....	40
3.4 Approches d'analyse de la texture.....	42
3.4.1 Approche structurelle.....	42
3.4.2 Approche spatio-fréquentielle.....	43
3.4.3 Approche statistique.....	43
3.4.4 Approche basée sur les vecteurs de Rang.....	45
3.5 Méthodes de classification d'images multispectrales.....	47
3.5.1 Classification par la méthode du parallélépipède (hypercubes).....	48
3.5.2 Classification par minimisation de distance.....	49
3.5.2.1 Classification par la méthode des K plus proches voisins.....	50
3.5.2.2 Méthode des K-means.....	50
3.5.2.3 Classification par ISODATA	51
3.5.2.4 Classification par Fuzzy-C-means.....	52
3.5.3 Classification par la méthode du maximum de vraisemblance.....	53

3.5.4 Classification contextuelle par les Champs de Markov.....	56
3.5.4.1 Champs de Markov.....	56
3.5.4.2 Equivalence entre champs de Gibbs et de Markov.....	56
3.5.4.3 Recherche de la configuration la plus probable	58
3.5.4.4 Applications dans la classification des images	59
3.5.5 Machines à Support Vecteurs.....	60
3.5.5.1 Principe de base des SVM.....	61
3.5.5.2 Cas non linéairement séparable.....	62
3.5.6 Réseaux de neurones.....	64
3.5.6.1 Les perceptrons multicouches.....	64
3.5.6.2 Apprentissage par rétropropagation du gradient.....	66
 3.6 Etude comparative des méthodes de classification en télédétection.....	 72
 3.7 Conclusion.....	 74

Chapitre 4 : Approche adoptée pour l'identification et la classification des nuages précipitants

4.1 Préambule.....	75
4.2. Présentation du site d'étude et des données utilisées.....	76
4.2.1. Présentation du site.....	76
4.2.2. Données utilisées.....	76
a. Données du satellite MSG.....	77
b. Données du radar météorologique de Sétif.....	78
4.3. La méthode Convective Stratiforme « Convective Stratiform Technique (CST) ».....	81
4.4. Méthodologie de l'approche développée d'identification et de classification des nuages précipitants (RACT-DN)	82
4.4.1 Paramètres spectraux.....	83
4.4.2 Paramètre temporel.....	85
4.4.3 Paramètres de texture.....	88
4.4.4. Méthode d'identification et de classification des nuages précipitants.....	88
4.4.5 Résultats et évaluation des performances.....	90
A. Analyse statistique.....	91
B. Analyse des résultats.....	93
Identification des nuages précipitants.....	93
Classification des nuages précipitants en convectifs et stratiformes.....	94
CONCLUSION	98

Bibliographie

INTRODUCTION

L'objet de cette thèse est de proposer une méthode de segmentation et de classification d'images météorologiques issues du satellite météorologique (MSG) pendant le jour et la nuit. L'approche adoptée permet d'une part, de segmenter l'image en régions de précipitation et de non précipitation et, d'autre part, de classer les nuages précipitants en deux classes principales: convectives et stratiformes.

Les précipitations, à travers le stockage, le transport et la libération de la chaleur latente associés aux processus de formation sont la source d'énergie principale à la base de la circulation atmosphérique. Cela constitue environ 75% de l'énergie sous forme de chaleur dans l'atmosphère. Une connaissance précise des précipitations est donc cruciale pour la compréhension du temps et du climat, et ceci à toutes les échelles [Levizzani et Mugnai 2004].

Cependant, la forte variabilité à la fois spatiale et temporelle des précipitations les rend extrêmement difficile à déterminer [Gorenburg et al. 2004]. Les méthodes basées sur des mesures au sol conduisent à une estimation satisfaisante des précipitations, mais seulement de façon locale et sans suivi possible de l'évolution temporelle des systèmes précipitants. De plus les mesures au dessus des océans, qui représentent à eux seuls 70% de la surface du globe, ne sont pas accessibles.

Une des tâches importantes est donc l'analyse des systèmes précipitants, en particulier dans les zones tropicales où les images satellites constituent une source d'information indispensable: les tropiques étant couverts à 75% par les océans, seule une étude des précipitations depuis l'espace peut permettre une estimation globale. De plus, dans les régions où il ya un manque ou dépourvues d'instruments de mesures des précipitations au sol tels que les pluviomètres ou les radars, l'exploitation des données satellite reste alors l'unique moyen pour l'estimation des précipitations.

La région de notre étude est située au nord de l'Algérie et possède un climat méditerranéen. La Méditerranée est une région du globe qui, du fait de sa situation géographique et de son relief particulier bénéficie d'un climat bien spécifique, à la frontière entre les climats de moyennes latitudes et sub-tropicaux. Fortement influencé par la mer, le climat méditerranéen est protégé de l'empreinte de

l'Atlantique et des plus hautes latitudes par le relief de la région. Ce climat est caractérisé par une forte variabilité avec de longues périodes de sécheresse en été et des hivers plus humides associés à des précipitations peu fréquentes mais intenses, notamment en inter-saison de type convectives et stratiformes. Les phénomènes météorologiques extrêmes y sont importants. Sécheresse, vents violents, pluies intenses et crues rapides font régulièrement de lourds dégâts matériels et parfois humains.

Les méthodes d'estimation des paramètres météorologiques tel que le taux de précipitation ont besoin pour la plupart d'être associées à une technique d'identification et de classification automatique des nuages précipitants. Plusieurs approches d'estimation des précipitations à partir des données satellites ont été développées au cours des dernières années. La plupart de ces méthodes utilisent des mesures dans l'infrarouge thermique [Adler et Negri 1988; Reudenbach et al. 2001; Levizzani et al. 2001; Levizzani 2003]. Cependant, les données infrarouges sont des mesures de radiance ou de température des sommets des nuages et n'ont pas un rapport physique direct avec les précipitations. De plus, ces méthodes associent les températures froides des nuages hauts à des systèmes fortement convectifs et donc probablement précipitants. Une des difficultés de ces approches est le choix du seuil de température à partir duquel un nuage est considéré comme étant froid. De plus, l'utilisation de la température de brillance des sommets des nuages comme paramètre dans les techniques de classification est insuffisant dans le cas des nuages stratiformes précipitants de faible altitude et qui ont des températures chaudes [Ebert et al. 2007; Früh et al. 2007].

Le satellite MSG (Meteosat Second Generation) fournit des images de haute résolution spatiale, temporelle et spectrale toutes les 15 minutes à travers 12 canaux (visibles, infrarouges et proche infrarouges). L'exploitation de ces données permet d'extraire les paramètres microphysiques et optiques des nuages précipitants permettant ainsi d'améliorer les résultats d'identification des précipitations [Ba et Gruber 2001; Kühnlein et al. 2010 ; Nauss et Kokhanovsky 2006; Roebeling et Holleman 2009; Rosenfeld et Gutman 1994; Rosenfeld et Lensky 1998; Thies et al. 2008a, 2008b, 2008c].

Par ailleurs, les zones de précipitation peuvent être classées en régions convectives et stratiformes [Tremblay 2005]. Les nuages convectifs sont caractérisés par des taux de précipitation élevés et de courte durée comparé aux nuages stratiformes qui couvrent une grande étendue, de faible intensité mais dure longtemps [Hong et al. 1999].

Les algorithmes de classification des régions précipitantes en convectives et stratiformes contribuent à l'amélioration de la précision de l'estimation des précipitations [Simpson et al. 1998]. En effet, différentes méthodes d'estimation des précipitations utilisent des techniques de caractérisations des nuages convectives et stratiformes [Lazri et al. 2013; Feidas et Giannakos 2012 ; Laviola et Levizzani 2011; Anagnostou et Kummerow 1997; Inoue 1987b; Adler et Negri 1988; Arkin et Meisner 1987].

Par ailleurs, la texture des nuages est liée à leurs apparences physiques dans les canaux visibles et infrarouges. En effet, les nuages convectifs sont caractérisés par une texture granuleuse et irrégulière, alors que les nuages stratiformes ont une apparence lisse et parfois fibreuse. Par conséquent, le paramètre de texture permet d'améliorer les résultats d'identification et de classification des nuages précipitants [Ameur et al. 2004; Ameur et al 2006 ; Uddstrom et Gray 1996 ; Kaur et Ganju 2008; Giannakos et Feidas 2013].

La méthode d'identification et de classification jour et nuit des nuages précipitants que nous avons développée RACT-DN [Sehad et al. 2014b] est basée sur des caractéristiques spectrales, texturales et temporelles. Les paramètres spectraux correspondent à la structure microphysique, épaisseur optique, température, et à la phase (liquide, glace) des nuages précipitants. Le paramètre de texture a été calculé à partir de la méthode des vecteurs de rang [Ameur et al 2006]. Le paramètre temporel représente le taux de variation de la température des nuages entre deux images consécutives [Vicente et al. 1998].

La classification a été réalisée par deux réseaux de neurones perceptrons multicouches : MLP-D pendant jour et MLP-N pendant la nuit. Aussi, l'apprentissage de ces deux réseaux a été réalisé en utilisant une base de données constituée d'images satellite et Radar prises dans la région de Sétif durant la période de Novembre 2006 à Mars 2007. La validation de notre approche a été réalisée avec des images prises durant la période de Novembre 2010 à Mars 2011.

Enfin, les résultats obtenus par notre approche ont été comparés d'une part, avec ceux obtenus par radar et d'autre part, avec la méthode de référence ECST (Enhanced Convective Stratiform Technique) [Reudenbach et al. 2001].

Le travail que nous présentons dans cette thèse a été organisé en quatre chapitres :

Le premier chapitre porte sur la physique des nuages et les précipitations.

Le deuxième chapitre est dédié à la présentation des instruments de télédétection utilisés en météorologie à savoir les satellites et les radars.

Le troisième chapitre, nous présentons un état de l'art des différentes approches de segmentation et de classification des images de télédétection.

Le quatrième chapitre est consacré, d'une part, à la présentation de la méthode d'identification et de classification des nuages précipitants que nous avons élaboré, et d'autre part, à la présentation et à l'analyse des résultats obtenus par notre approche.

Et nous terminons par une conclusion.

Chapitre 1

Nuages et précipitations

1.1 Préambule

Le climat méditerranéen est caractérisé par un fort contraste entre l'été et l'hiver, surtout pour les précipitations et le cycle hydrologique à la surface. Des mécanismes climatiques complexes y opèrent et font intervenir l'atmosphère, l'océan nord-atlantique, la mer méditerranée, les glaciers alpins, la végétation continentale et les aérosols d'origine désertique ou anthropique. La Méditerranée est enfin une zone de transition entre un climat chaud et sec au sud et un climat doux et humide au nord. Ceci implique que la méditerranée et son écosystème sont sensibles et vulnérables au changement climatique. Par conséquent, cette région est caractérisée par une occurrence importante des précipitations convectives et des précipitations stratiformes. Les premières sont liées à l'instabilité atmosphérique des systèmes de méso échelle et les secondes sont liées aux systèmes frontaux de grande échelle.

Nous proposons dans ce chapitre de donner quelques éléments de physique des nuages et des précipitations. Nous limitons notre présentation aux caractéristiques principales des nuages et des précipitations. Les nuages sont tout d'abord considérés: leur contenu, leur classification, leur mode de formation d'un point de vue thermodynamique et microphysique sont discutés. Les différentes formes de précipitations, leur apparition dans un nuage et les mécanismes microphysiques impliqués dans leur développement sont ensuite présentés. Par la suite, nous abordons l'étude des nuages et des précipitations dans le contexte atmosphérique dans lequel les aspects macroscopiques et environnementaux doivent être pris en compte. Enfin, nous terminons par l'étude des propriétés radiatives des précipitations et des nuages.

1.2 Caractéristiques et classification des nuages

1.2.1. Définition

La taille des hydrométéores nuageux varie du micromètre au millimètre. Pour des gouttelettes nuageuses, sphériques, le diamètre D est généralement inférieur à $100\ \mu m$. Pour des cristaux dont la géométrie est plus complexe, des tailles caractéristiques peuvent être observées jusqu'à $2\ mm$. Ces dimensions correspondent à des vitesses limite de chute inférieures à $1\ m/s$, ce qui est suffisant pour que les mouvements d'air ascendants, même faibles, maintiennent en altitude ces hydrométéores.

Les nuages constitués uniquement d'eau liquide contiennent typiquement quelque 100 à 1000 gouttelettes d'eau par cm^3 . Cependant, les nuages sont des milieux dispersés : la distance moyenne entre gouttelettes d'eau est environ 100 fois supérieure à leur diamètre moyen. Dans les nuages contenant des cristaux de glace, la dispersion des particules est plus grande que celle des gouttelettes d'eau.

1.2.2. Classification des nuages

Il existe différents types de nuages précipitants et non précipitants selon leurs formes et altitudes. L'organisation météorologique mondiale (OMM) a classé les nuages en dix genres correspondant selon leur caractéristiques : forme, altitude, extension verticale et leur structure cumuliforme ou stratiforme (figure 1.2). La classification des nuages d'après l'organisation météorologique mondiale est donnée par (Table 1.1 et figure 1.1).

1.3 Formation des nuages

1.3.1. Condition nécessaire à la formation d'un nuage

La formation des nuages relève de la thermodynamique de l'air humide qui est composé d'un mélange d'air sec et de vapeur d'eau. La description de ce système nécessite trois variables d'états.

Groupe	Altitude moyenne de la base	Préfixe du nom du nuage
Nuages élevés	6000 mètres	Cirr...
Nuages moyens	2000 mètres	Alto...
Nuages bas	Du sol à 2000 mètres	Stra...
À développement vertical	500 mètres	Cum...

Table1.1 Classification des nuages selon l'altitude




Fig. 1.1 Classification des nuages selon L'OMM



Cirrus



Cirrostratus



Cirrocumulus



Altostratus



Altostratus



Stratocumulus



Stratus



Nimbostratus



Cumulus



Cumulonimbus

Fig. 1.2 Genres de nuages(Source : Météo-France (<http://www.meteo.fr>)).

L'humidité relative (H) est le rapport entre la pression de la vapeur d'eau dans le nuage et la pression de vapeur saturante qui correspond à la quantité maximale de vapeur d'eau que peut contenir une masse d'air sans condensation. Ainsi, si $H=0\%$ l'air est sec et saturé si $H \geq 100\%$.

Par ailleurs, un nuage se forme lorsqu'une masse d'air humide est saturée en vapeur d'eau. La transformation thermodynamique s'effectue au cours de l'ascension dans l'atmosphère d'une masse d'air humide initialement non saturé.

Comme la pression de vapeur saturante est proportionnelle à la température, l'air ascendant atteint la saturation lorsque la pression de la vapeur d'eau est égale à la pression de vapeur saturante.

1.3.2. Formation de gouttelettes nuageuses à partir de la vapeur d'eau

Le processus de formation de gouttelettes d'eau à partir de la vapeur d'eau est appelé condensation. Ce mécanisme est basé sur la nucléation : formation d'un noyau de la nouvelle phase. Cette opération nécessite la formation d'une interface entre la vapeur et la phase liquide. Le noyau formé est instable et son développement dépend de la saturation ou sursaturation de la vapeur et de la taille du noyau.

Les conditions de sursaturations nécessaires à la formation de noyaux de taille suffisante pour la formation de gouttelettes d'eau nuageuses ne sont pas toujours réunies dans l'atmosphère. L'apparition de gouttelettes nuageuses est alors due à la présence de particules solides (aérosols) qui servent de noyaux.

1.3.3. Formation des cristaux de glace

La formation de cristaux de glace nécessite d'une part que la température soit négative, et d'autre part, l'existence de noyaux (nucléation homogène) pour la formation de cristaux de glace à partir de la vapeur ou des gouttelettes d'eau.

Dans l'atmosphère les conditions pour la formation de noyaux de congélation (sursaturation plus importante que la condensation) ne sont pas réunies. On admet alors que les cristaux de glace sont formés par congélation de gouttelettes d'eau surfondue. Le cristal de glace se forme alors en

deux temps : la naissance d'une gouttelette d'eau surfondue autour d'un noyau de condensation, ensuite, la congélation de la gouttelette par un noyau de congélation.

Certain auteurs pensent que les cristaux de glace peuvent se former par solidification de la vapeur d'eau autour des noyaux de solidification : cas des cirrus.

1.4 Des hydrométéores nuageux aux précipitations

Il existe différentes formes de précipitations: liquides comme la pluie et solides comme la neige et la grêle. Ce sont des particules qui, contrairement aux hydrométéores nuageux, ne restent pas en suspension dans une atmosphère calme et tombent au sol en raison de leur taille importante. L'observation montre que les précipitations se développent généralement en quelques dizaines de minutes une fois les nuages formés.

1.4.1. Précipitations liquides

Les gouttelettes nuageuses sont précipitantes si leur diamètre est supérieur ou égal à $100\ \mu\text{m}$ [Glickman 2000]. La formation de la pluie est due au processus de coalescence : collision de gouttelettes entre elles pour former un élément plus gros : gouttes. Ce processus est efficace si les gouttelettes d'eau ont des tailles et des vitesses variées.

1.4.2. Précipitations solides

Le cristal de glace est l'élément de base pour la formation des précipitations solides. L'agrégation de cristaux de glace conduit à la formation de différentes formes de cristaux : la rosette ou flocon de neige.

Par ailleurs, des structures beaucoup plus denses comme les particules givrées se forment lorsque des cristaux de glace ou de la neige heurtent des gouttelettes ou des gouttes d'eau surfondues. Des particules glacées ou givrées fondent au passage par $0\ ^\circ\text{C}$ et forment des gouttes d'eau qui grossissent par coalescence. Ces dernières peuvent être ramenées en altitude par des vents ascendants où elles gèlent pour donner des particules solides plus grosses. La répétition de ce processus donne de grosses particules glacées, dures, compactes et sphériques: les grêlons et la grêle.

1.5 Précipitations stratiformes ou convectives

La nature des mouvements d'air verticaux permet de distinguer principalement deux types de précipitations : *stratiformes* et *convectives*. Les processus microphysiques des précipitations stratiformes se déroulent dans des mouvements d'air verticaux relativement faibles contrairement aux précipitations convectives caractérisées par de forts vents ascendants, on a alors :

$$\text{Précipitations stratiformes : } |v^{air}| \ll |v^{cristaux}| \quad (1.1)$$

$$\text{Précipitations convectives : } |v^{air}| \geq |v^{cristaux}| \quad (1.2)$$

Où, v^{air} désigne la vitesse verticale de l'air et $v^{cristaux}$ la vitesse limite de chute correspondant à des hydrométéores de taille proche de celles de cristaux de glace ou de neige ($\approx 1 \text{ m s}^{-1}$) [Yuter et Houze 1995 ; Houze 1997].

Dans le cas de précipitations convectives, les forts mouvements ascendants conduisent à une rapide condensation de la vapeur d'eau et génèrent d'importants contenus en eau liquide nuageuse. Les processus microphysiques dominants sont la coalescence et le givrage [Houghton 1968]. De plus, les fortes ascendances augmentent la durée de résidence des hydrométéores dans les nuages convectifs permettant ainsi une augmentation de la taille des particules qui tombent au sol sous forme de pluies très fortes et/ou de grêle. Parmi les précipitations convectives, on peut citer les cumulonimbus.

Dans le cas de précipitations stratiforme, les ascendances sont moins fortes ($< 1 \text{ m s}^{-1}$), les contenus en eau liquide nuageuse sont plus faibles et la croissance des précipitations se fait par les processus de diffusion et d'agrégation. Ces particules tombent et grossissent en formant quelques agrégats de neige, fondent au passage par 0°C et augmentent les précipitations liquides qui atteignent parfois le sol. Si la température est négative, les précipitations restent sous forme solide comme la neige : nuages de type nimbostratus.

1.6. Précipitations stratiformes et convectives

Les précipitations stratiformes et convectives peuvent coexister au sein du même système précipitant. En effet, un système convectif, jeune et actif, évolue toujours vers un système stratiforme. Yuter et Houze (1995) proposèrent un modèle pour expliquer cette transition observée dans des cumulonimbus : le modèle de la fontaine de particules.

Le système est représenté par un ensemble de masses d'air localisées, en mouvement ascendant, contenant un grand nombre d'hydrométéores, et à l'intérieur desquelles les précipitations, liquide et/ou solides, se développent principalement par coalescence et givrage. Au cours de l'ascension, les particules devenant trop lourdes tombent à travers l'ascendance alors que, les plus légères (majoritairement des cristaux de glace, quelquefois des gouttelettes d'eau) sont portées en altitude par la masse d'air qui au fur et à mesure de son élévation ralentit et s'étend horizontalement. Il s'ensuit un éparpillement horizontal des hydrométéores légers qui se retrouvent alors dans des zones de plus faibles mouvements verticaux. C'est cette façon de distribuer les hydrométéores qui suggère l'expression de fontaine de particules et c'est l'ensemble des trajectoires des particules qui constitue une fontaine.

1.7. Propriétés radiatives des précipitations et des nuages

Les propriétés radiatives des nuages dans les longueurs d'onde visible (VIS), proche infrarouge (NIR) et infrarouge (IR) ont depuis longtemps été étudiées [Arking et Childs 1985]. Ces propriétés radiatives peuvent être résumées comme suit [Levizzani et al. 2001]:

- Dans l'infrarouge thermique, les propriétés radiatives sont sensibles à la distribution de la taille des hydrométéores. En effet, une augmentation de la taille des particules augmente la transmissivité, diminue la réflectivité et augmente l'émissivité des nuages.
- L'émissivité des nuages de glace est inférieure à celle des nuages d'eau.
- Dans la bande (3.7-3.9 μm), l'émissivité des nuages est plus faible que dans l'infrarouge thermique (10.5 - 12.5 μm).

- Nuages avec des petits hydrométéores diffusent et reflètent une grande partie du rayonnement dans la bande (3.7 - 3.9 μ m). Une augmentation de la taille des particules des nuages ou de la présence de grosses gouttes ou cristaux de glace au sommet du nuage réduit la réflectance dans la bande (3.7 - 3.9 μ m).
- La réflectance dans le NIR (1,50 - 1,78 μ m) est inversement proportionnelle à la taille des rayons effectifs des particules de nuages.
- La réflectance dans la bande VIS est proportionnelle à l'épaisseur optique du nuage.

Le rayon effectif r_e est défini comme le rapport du troisième sur le second moment du spectre dimensionnel des gouttelettes, soit [Levizzani et al. 2001] :

$$r_e = \frac{\int_0^\infty r^3 n(r) dr}{\int_0^\infty r^2 n(r) dr} \quad (1.3)$$

Où r est le rayon des gouttelettes de nuages et $n(r)$ est la concentration de gouttelettes de rayon r .

La teneur en eau liquide des nuages : LWC (liquid water content) pour les nuages d'eau ou IWC (ice water content) pour les nuages de glace), est également largement utilisée pour caractériser la microphysique des nuages et elle est définie comme suit [Levizzani et al. 2001] :

$$LWC = \frac{4\pi\rho_w}{3} \int_0^\infty n(r) r^3 dr \quad (1.4)$$

Où ρ_w est la densité de l'eau.

L'épaisseur optique des nuages correspond à la capacité du nuage à « éteindre » un faisceau lumineux. Elle est définie par l'intégration du coefficient d'extinction sur l'épaisseur géométrique de nuage (Levizzani et al. 2001):

$$\tau = \int_{z_1}^{z_2} k dz \quad (1.5)$$

Où z_1 et z_2 sont la hauteur de la base du nuage et la hauteur du sommet du nuage, respectivement, et k est le coefficient d'extinction.

LWP (liquid water path) représente la quantité d'eau liquide intégrée sur la colonne atmosphérique (en g m^{-2}). LWP s'exprime par la relation suivante [Levizzani et al. 2001] :

$$LWP = \int_{z_1}^{z_2} LWC(z) dz \quad (1.6)$$

CWP (cloud water path) est défini comme LWP pour le nuage d'eau ou IWP pour le nuage de glace. Le paramètre CWP est proportionnel à l'épaisseur optique des nuages τ et au rayon effectif des particules des nuages r_e . La relation est donnée par l'équation (1.7) [Thies et al, 2008 ; Nauss et Kokhanovsky 2006, 2007] :

$$CWP = \frac{2}{3} \rho \cdot \tau \cdot r_e \quad (1.7)$$

Où ρ (g/m^3) est la densité de l'eau dans les nuages.

Le paramètre CWP est directement lié à la probabilité qu'un nuage soit précipitant. Aussi, la présence des particules de glace (phase des nuages) dans la partie supérieure de nuage augmente la probabilité qu'un nuage soit pluvio-gène.

1.8. Discussion

Nous avons exposé dans chapitre les différents types de précipitations dans la région méditerranéenne à savoir convectives et stratiformes ainsi que leurs caractéristiques microphysiques, macrophysiques et optiques. Dans le but d'identifier et de classer les nuages précipitants en convectifs et stratiformes, nous allons utiliser des dispositifs de télédétection à savoir les satellites et les radars météorologiques que nous présenterons dans le chapitre suivant.

Chapitre 2

Dispositifs d'Imagerie Satellitaire et Radar en Météorologie

2.1 Préambule

Notre travail de thèse porte sur l'identification et la classification des nuages précipitants à partir d'images infrarouges issues du satellite météorologique MSG et des données radar. Par conséquent, Il est important de présenter les dispositifs d'imagerie satellitaire et radar qui nous ont permis d'avoir des images sur lesquelles notre travail est basé. Après quelques notions de base en télédétection, nous présentons dans ce chapitre d'une part, les différents satellites météorologiques et en particulier le satellite METEOSAT de deuxième génération MSG, et d'autre part, nous détaillons le principe de fonctionnement du radar météorologique.

2.2 Principe de la télédétection

La télédétection comprend l'ensemble des procédés et techniques qui permettent d'acquérir à distance des informations sur les objets terrestres, en utilisant les propriétés des ondes électromagnétiques émises ou réfléchies par ces objets. L'acquisition dans plusieurs bandes, ou intervalles de longueurs d'onde, permet d'identifier les objets par l'étude de leur signature spectrale.

2.2.1 Les longueurs d'onde

La télédétection spatiale n'utilise qu'une partie du spectre électromagnétique, on distingue les domaines solaire ($\lambda = 0.38$ à $3 \mu\text{m}$), infrarouge thermique ($\lambda = 3$ à $1000 \mu\text{m}$), et micro-onde ($\lambda = 10^{-3} \text{ m}$ à 0.3 m) (Figure 2.1). Le rayonnement est réfléchi par la surface dans le domaine solaire, émis dans l'infrarouge thermique; il peut être émis ou réfléchi dans le domaine des micro-ondes en fonction du caractère passif ou actif du système d'observation.




Fig. 2.1 Spectre du rayonnement et transparence de l'atmosphère.

- Les spectres d'émission du Soleil et de la Terre se croisent autour de trois microns :
 - les ondes plus courtes (domaine optique) sont majoritairement émises par le Soleil et réfléchies par la Terre.
 - les ondes plus longues (domaine thermique) sont majoritairement émises par la Terre.
- L'observation de la Terre par imagerie thermique se heurte à deux principales difficultés :
 - Pour les longueurs d'onde les plus courtes (typiquement 3 à 5 microns) l'émission propre de la Terre est contaminée par la réflexion du rayonnement solaire : il est donc recommandé de faire des observations nocturnes.

- Pour les longueurs d'onde proches du maximum d'émission (typiquement 8 à 14 microns) il est nécessaire de refroidir le plan focal du capteur (par exemple en le maintenant en contact avec de l'air liquide) afin de diminuer son émission propre.

2.2.2. Réfraction atmosphérique

La réflexion d'une onde incidente sur la surface terrestre dépend des caractéristiques de l'onde (longueur d'onde, polarisation, angle d'incidence,...) et des caractéristiques de la surface (matériau, pente, rugosité, humidité,...). En fonction de ces caractéristiques la réflexion peut être spéculaire (effet de miroir) ou diffuse.

Le rapport de l'énergie réfléchie à l'énergie totale incidente est appelé albédo. En télédétection optique la réflectance désigne la proportion d'énergie réfléchie dans une direction donnée, notamment dans la direction du capteur. La variation de la réflectance en fonction de la longueur d'onde est appelée signature spectrale.

2.2.3. Notion de signature

La signature est une grandeur physique qui permet de caractériser les objets observés, et que l'on peut déduire à partir des images. Une signature peut être obtenue à partir de modèles théoriques (simulations) ou par des mesures réelles.

Pour caractériser la nature d'une surface, on utilise des grandeurs normalisées :

- la réflectance pour les images optiques ;
- l'émissivité pour les images thermiques ;
- le coefficient de rétrodiffusion pour les images radar.

La signature est une grandeur qui dépend d'une part des caractéristiques de l'onde incidente et d'autre part des caractéristiques de l'objet observé. La réflectance dépend de la nature du matériau mais aussi de la longueur d'onde (Figure. 2.4).




Fig. 2.4 Spectres typiques de réflectances de la neige, de l'eau, du sol et de la végétation.

2.3 L'observation spatiale

Les capteurs optiques sont des radiomètres imageurs qui mesurent une énergie rayonnée provenant d'une région bidimensionnelle et qu'ils organisent les mesures sous forme d'images. Ils fonctionnent dans les longueurs d'onde optiques, qui se situent entre l'ultraviolet et l'infrarouge thermique.

Chaque détecteur reçoit, par le biais d'une optique et d'un certain nombre de mécanismes, une énergie $E(\Omega, t, \lambda)$ qu'il mesure avec une réponse spectrale $R(\lambda)$ et intègre sur un angle solide $\Delta\Omega$, pendant un temps d'intégration Δt et sur une bande spectrale $\Delta\lambda$. On obtient la mesure (m), ajustée par un coefficient d'étalonnage A :

$$m = A \cdot \int \int \int E(\Omega, t, \lambda) \cdot R(\lambda) d\Omega \cdot dt \cdot d\lambda \quad (2.1)$$

2.3.1. Principe de fonctionnement d'un capteur optique

Un capteur optique analogique est conçu pour recueillir et focaliser un rayonnement lumineux (partie optique) et pour sensibiliser une surface photosensible. Un capteur optronique est conçu pour recueillir et focaliser un rayonnement lumineux et pour la convertir en un signal électrique.

➤ **Plan focal**

La surface contenant les détecteurs doit se situer le plus près possible de la surface focale de l'objectif. C'est pourquoi on conçoit les objectifs pour qu'ils aient une surface focale plane, et on appelle plan focal la plaque qui supporte les détecteurs.

Le détecteur est un matériau sensible aux rayonnements. Plusieurs phénomènes physiques peuvent être à la base du fonctionnement d'un détecteur :

- Effet thermique : le rayonnement modifie la température du matériau.
- Effet électromagnétique: le rayonnement modifie les propriétés électromagnétiques du matériau (conductivité,...) ;
- effet photonique : le rayonnement libère des électrons dans le matériau. Ce dernier effet est utilisé dans les détecteurs CCD en télédétection optique. Ces détecteurs sont constitués d'alliages, généralement à base de silicium.

➤ **Balayage mécanique**

Le processus d'acquisition se fait selon deux directions (Figure 2.6): la première est celle de l'avancement de la plateforme et définit les lignes de l'image (direction parallèle à la trace du satellite ou *in-track*), la deuxième est la direction perpendiculaire à la première et définit les colonnes de l'image (direction *cross-track*). Le capteur observe la scène sous un angle appelé champ de vue (*FOV: Field Of View*), qui intervient dans la définition de la largeur du champ d'observation (*GFOV: Ground Field Of View*), appelée fauchée. Ce processus entraîne la formation d'une image, qui possède des caractéristiques de nature spatiale, temporelle, directionnelle et spectrale. Ces caractéristiques dépendent de l'orbite sur laquelle évolue la plateforme spatiale, des propriétés des capteurs et des conditions d'observations.




Fig. 2.6 Mesure dans le plan d'avancement du capteur (Garrigues 2004).

2.3.2. Caractéristiques des images

- La résolution spectrale décrit la capacité d'un capteur à utiliser des plages de longueurs d'onde spécifiques appelées bandes spectrales. Ces bandes sont définies par leur nombre, leur position et leur largeur.
- La résolution spatiale d'un capteur peut être au premier ordre assimilée à la taille des éléments de surface élémentaires observés, éléments constitutifs de l'image appelés pixels. La résolution spatiale est obtenue en multipliant le terme IFOV par l'altitude de la plateforme.
- La résolution temporelle dépend du cycle orbital d'un capteur. Ce cycle correspond au temps que met un capteur pour observer un même point de la surface de la terre dans les mêmes conditions de visée.

2.4 Satellites météorologiques

Un satellite météorologique est un satellite artificiel qui a comme mission principale le recueil de données utilisées pour la surveillance du temps et du climat de la Terre. Chaque nouvelle génération de satellite comporte des capteurs plus performants et capables d'effectuer des mesures sur un plus grand nombre de canaux ce qui permet de les utiliser pour différencier les divers phénomènes météorologiques : nuages, précipitations, vents, brouillard, etc.

Plusieurs pays lancent et maintiennent des réseaux de satellites météorologiques : les États-Unis, les pays européens, l'Inde, la Chine, la Russie et le Japon. Tous ces satellites assurent une couverture globale de l'atmosphère. Ce réseau opérationnel de satellites météorologiques est sous la responsabilité de quatre opérateurs satellitaires : EUMETSAT (Europe), JAXA (Japon), FKA (Russie) et NASA (Etats-Unis). Finalement, le système mondial de satellites météorologiques opérationnels comprend une constellation d'au moins cinq satellites régulièrement espacés autour de l'équateur en orbite géostationnaire, et au moins deux satellites en orbite quasi polaire (Fig.2.8).



Fig. 2.8 Satellites météorologiques opérationnels exploités au Centre de Météorologie Spatial (source EUMETSAT).

2.4.1 Les satellites géostationnaires

Les satellites géostationnaires tournent dans le même sens que la Terre avec la même vitesse de rotation et sur une orbite au-dessus de l'Equateur. Ils sont situés à 36 000 km d'altitude au-dessus de l'Équateur. Chaque satellite géostationnaire a la capacité de fournir de manière quasi-continue des images et des services de télécommunications au-dessus d'une large région de la

planète et peut produire des images couvrant pratiquement un quart de la surface terrestre jour et nuit (Fig. 2.9).

Le système de satellites actuellement en opération comprend Météosat (EUMETSAT), GOES (Etats-Unis), GOMS (Russie), MTSAT (Japon) qui a remplacé la série de GMS et FY- 2 (Chine). Ces satellites ont été conçus pour des applications météorologiques.




Fig. 2.9 Couverture des satellites météorologiques géostationnaires (source EUMETSAT).

2.4.2 Les satellites polaires

Les satellites à orbites polaires donnent une vue plus globale de la Terre. Ils tournent autour de la Terre avec une inclinaison proche des pôles. Ils se trouvent à une altitude de 700 à 800 km, et ils couvrent le mieux les parties de la Terre qui sont difficiles d'accès. Les satellites en orbite polaire peuvent balayer une bande de la Terre, en prenant moins de deux heures pour compléter une orbite. A chaque passe, ils examinent une bande d'une largeur d'environ 1900 kilomètres qui se situe plus à l'Ouest à cause de la rotation de la Terre vers l'Est. Chaque satellite en orbite polaire peut observer la planète entière en 24 heures.

2.5 Le satellite METEOSAT

Les satellites METEOSAT sont des satellites géostationnaires européens dont le propriétaire et l'opérateur sont EUMETSAT. La première utilisation de ses images est évidemment destinée à la prévision météorologique (figure 2.10). Le champ visuel couvre l'Afrique, l'Europe et les extrémités de l'Asie et de l'Amérique méridionale.




Fig. 2. 10 Concept du satellite METEOSAT (source EUMETSAT).

2.5.1 METEOSAT de première génération

Le satellite METEOSAT de première génération (figure 2.11) est un satellite météorologique géostationnaire européen. Il offre ses services à tous les pays du monde capables de recevoir les données. Les données et services sont dédiés principalement aux besoins de la météorologie.




Fig. 2.11 Le satellite METEOSAT : le radiomètre se trouve derrière la large ouverture ovale dans le corps principal du satellite, les systèmes d'antenne sont situés sur le sommet de l'appareil (source EUMETSAT).

Le programme est opérationnel depuis 1970. Sept satellites METEOSAT de première génération ont été lancés depuis cette période (Table 2.1):

Satellite	Date de lancée
METEOSAT-1	23 Novembre 1977
METEOSAT-2	19 Juin 1981
METEOSAT-3	15 Juin 1988
METEOSAT-4	06 Mars 1989
METEOSAT-5	02 Mars 1991
METEOSAT-6	20 Novembre 1993
METEOSAT-7	02 Septembre 1997

Table 2.1 Programme de lancée des satellites METEOSAT de première génération

Quelques changements relativement dans la structure du satellite et dans les caractéristiques des sondes ont été introduits dans METEOSAT-4, lancés en 1989, et conservés sur tous les satellites suivants de METEOSAT. METEOSAT-7 est le dernier satellite de première génération. Il est de poids réduit avec une masse de 720 kg et a une durée de vie de 5 ans. Il est opérationnel à 0° de longitude au-dessus du golfe de Guinée. La partie principale du corps du satellite est un cylindre de 2.10 m de diamètre pour une hauteur totale de 3.195 m. La surface du satellite est recouverte de milliers de cellules photoélectriques qui lui fournissent son énergie électrique. Les

deux extrémités sont occupées chacune par un système de refroidissement conique et une série d'antennes.

Il tourne à 100 tours/minute autour de son axe principal, orienté parallèlement à l'axe Nord-Sud de la Terre. Ceci permet la construction de l'image de la Terre à partir des balayages successifs sur une période de 25 minutes. Après cette période, le télescope est remis en position de démarrage sur une période de 5 minutes pour balayer à nouveau une nouvelle image plein-disque. Par conséquent, il délivre toutes les 30 minutes une image numérique.

Nom du canal	Longueur d'onde centrale (μm)	Bande spectrale (μm)
VIS	0,725	0,45 – 1
WV	6,4	5,7 – 7,1
IR	11,5	10,5 – 12,5

Table 2.2 Les canaux de METEOSAT première génération

Le principal instrument de ce satellite est le radiomètre MVIRI, dont les caractéristiques principales sont rapportées dans le tableau ci-dessus (Table 2.2). Il a trois canaux spectraux : une bande panchromatique (VIS) qui inclut la totalité de la bande spectrale du visible et la partie proche de la bande infrarouge, une bande thermique (IR) et une bande infrarouge moyenne (WV). Ce capteur est sensible au rayonnement émis par la surface de la Terre. Il fournit les données de base issues des rayonnements du spectre électromagnétique dans les domaines visible et infrarouge. La radiation incidente est filtrée dans le radiomètre puis transformée en signal électrique proportionnel à l'énergie de la radiation. Ce signal est codé sur 8 bits. Des images correspondant à trois bandes spectrales différentes sont ainsi disponibles à chaque acquisition du satellite.

2.5.2 Le satellite METEOSAT seconde génération

Le satellite MSG (METEOSAT Seconde Génération) (figure 2.12) a été mis en place pour assurer la relève de METEOSAT première génération. Il permet d'avoir une amélioration de l'imagerie. MSG-1 a été lancé le 28 août 2002. Il est positionné au dessus de l'équateur à 3.5°E, il est devenu pleinement opérationnel sous le nom de METEOSAT-8 à partir du 29 janvier 2004.




Fig. 2.12 Satellite MSG1 (source EUMETSAT).



Les deux instruments principaux du satellite sont les radiomètres SEVIRI (Spinning Enhanced Visible and InfraRed Imager) et GERB (Geostationary Earth Radiation Budget experiment). L'imageur SEVIRI fournit toutes les 15 minutes (au lieu de 30 minutes avec METEOSAT) une image de l'hémisphère observée par le satellite dans 12 bandes spectrales (Table 2.3) différentes du spectre visible et infrarouge, soit 4 fois plus que Meteosat 7. De plus, en réduisant de 30 à 15 minutes le rafraîchissement des données, MSG-1 permet aux climatologues et aux météorologues de déceler plus facilement le déclenchement des phénomènes à évolution rapide, comme les orages, les tempêtes de neige ou les bancs de brouillard. Aussi, une résolution au sol de 1 km dans le spectre visible au lieu de 2,5 km permet l'observation et le suivi de phénomènes localisés. Le radiomètre GERB fournit des données essentielles sur le bilan radiatif de la Terre.

Nom du canal	Longueur d'onde centrale (μm)	Bande Spectrale (μm)
VIS 0.6	0,635	0,56 – 0,71
VIS 0.8	0,81	0,74 – 0,88
IR 1.6	1,64	1,50 – 1,78
IR 3.9	3,92	3,48 – 4,36
WV 6.2	6,25	5,35 – 7,15
WV 7.3	7,35	6,85 – 7,85
IR 8.7	8,7	8,30 – 9,10
IR 9.7	9,66	9,38 – 9,94
IR 10.8	10,8	9,80 – 11,80
IR 12.0	12	11,00 – 13,00
IR 13.4	13,4	12,40 – 14,40
HRV	0,7	0,50 – 0,90

Table 2.3 Les canaux de MSG

2.5.2.1 Les canaux visibles

MSG-1 possède deux canaux visibles : VIS 0.6 et VIS 0.8. Les images provenant de ces canaux (Figure 2.13 et Figure 2.14). Ces canaux sont indispensables pour la détection et le suivi des masses nuageuses, la détermination des zones observées lors de prises de vue successives, ainsi que la surveillance de la surface des terres et des aérosols. Leur combinaison permet d'établir des indices de végétation.

**Fig. 2.13** Canal visible 0.6**Fig. 2.14** Canal visible 0.8

MSG-1 possède aussi un canal visible dénommé HRV qui est un canal visible à large bande avec une résolution de 1 km.

2.5.2.2 Les canaux vapeur d'eau

MSG-1 possède deux canaux : WV 6.2 et WV 7.3. Ces canaux permettent de mesurer la vapeur d'eau dans la mésosphère, et d'affecter une altitude aux nuages semi-transparents. Les deux canaux séparés permettent d'obtenir des informations sur le contenu en vapeur d'eau à différents niveaux de la troposphère (figure 2.15 et figure 2.16).




Fig. 2.15 Canal WV 6.2




Fig. 2.16 Canal WV 7.3

2.5.2.3 Les canaux infrarouges

MSG-1 possède sept canaux dans l'infrarouge :

➤ Le canal IR 1.6

Ce canal est situé dans la partie dite proche infrarouge du spectre électromagnétique. Il aide à faire la différence entre surfaces nuageuses et surfaces neigeuses et entre nuages de glace et d'eau. Il apporte aussi des informations sur la présence d'aérosols atmosphériques.




Fig. 2.17 Canal IR 1.6

➤ **Le canal IR 3.9**

Il est situé dans une partie du spectre électromagnétique où la lumière du soleil influe sur le rayonnement reçu. Ainsi, il s'agit partiellement d'un canal d'émission thermique et il est aussi partiellement sensible à la réflexion du rayonnement solaire. Ce canal est utilisé principalement pour la détection des nuages bas, des brouillards nocturnes.




Fig. 2.18 Canal IR 3.9

➤ **Le canal IR 8.7**

Il apporte essentiellement des informations sur les masses nuageuses minces des cirrus et permet de faire la différence entre les nuages de glace et d'eau.




Fig. 2.19 Canal IR 8.7

➤ **Le canal IR 9.7**

Ce canal est sensible à la concentration d'ozone dans la partie basse de la stratosphère. Il sert à mesurer l'ozone total et à évaluer sa variabilité diurne.




Fig. 2.20 Canal IR 9.7

➤ **Les canaux IR 10.8 et IR 12.0**

Ils sont situés dans l'infrarouge thermique. Chaque canal réagit à la température des nuages et de la surface terrestre. Ensemble, ces canaux permettent de réduire les effets atmosphériques

en mesurant les températures de la surface de la Terre et du sommet des nuages. Ils servent aussi au suivi des nuages pour déterminer les vents atmosphériques.




Fig. 2.21 Canal IR 10.8




Fig. 2.22 Canal IR 12

➤ Le canal IR 13.4

Ce canal est situé dans la partie du spectre où le rayonnement est absorbé par les molécules de dioxyde de carbone (CO_2). Il sert à estimer l'instabilité atmosphérique et contribue à fournir des informations sur la température de la basse troposphère.




Fig. 2.23 Canal IR 13.4

2.6. Le radar météorologique

Le terme radar est l'acronyme de RAdio Detection And Ranging et désigne les appareils de télédétection conçus pour détecter et localiser des cibles par ondes radio (le terme radio est générique et désigne l'ensemble du spectre électromagnétique de longueur d'ondes du mm à la dizaine de km). En premier lieu, la technique du radar a été développée à des fins militaires, principalement pendant la seconde guerre mondiale, dans le but de détecter des avions. Les premières mesures de précipitations par radar ont été faites pendant cette période et ont d'abord été considérées comme un bruit perturbant la détection des avions ennemis. Depuis, la technique radar a beaucoup évolué, passant d'une description qualitative à des estimations quantitatives de nombreux paramètres météorologiques.

2.6.1. Principe du radar à impulsions

Un radar est composé de trois éléments principaux : un émetteur, une antenne et un récepteur. L'émetteur génère, à intervalles réguliers, des impulsions d'énergie électromagnétique, de forte puissance, de durée très brève mais avec une fréquence élevée. L'antenne focalise cette énergie en un faisceau dans une direction précise. L'énergie est ensuite en partie absorbée et réémise par toutes sortes de cibles présentes dans le faisceau. La partie d'énergie renvoyée en direction du radar est captée par le récepteur (en général, l'antenne sert à la fois pour l'émission et la réception) et constitue ce qu'on appelle l'écho radar. A chaque 5 minutes, le radar effectue une série de rotations azimutales de 360 degrés pour chacune des 24 élévations (rotations volumétriques de 1 km de résolution et de 1 degré d'azimut). Les données du radar ainsi obtenues sont emmagasinées pour chaque angle d'élévation ψ , chaque angle azimutal ϕ et chaque kilomètre en distance radiale. La figure 2.24 illustre le type de balayage radar et de volume spatial étudié.

Sur des distances inférieures à la centaine de kilomètres, on peut considérer que les ondes électromagnétiques se propagent en ligne droite et à vitesse constante (à la vitesse de la lumière). Alors, l'orientation de l'antenne et le délai entre l'émission et la réception du signal permettent de localiser la cible en direction et en distance. Les radars dits polarimétriques permettent d'avoir

une information sur la forme relative des cibles en émettant des ondes selon plusieurs polarisations.




Fig. 2.24 Le balayage du radar et le domaine spatial étudié

2.6.2. L'équation du radar pour la mesure des précipitations

On considère un émetteur qui rayonne de manière isotrope. P_e est la puissance totale émise et G le gain de l'antenne de surface effective A_e . Une cible située à la distance r et de section $S(r)$ intercepte donc la quantité de puissance P_σ donnée par :

$$P_\sigma = \frac{P_e \cdot G \cdot S(r)}{4\pi r^2} \quad (2.2)$$

Si la cible n'absorbait aucune puissance mais la réémettait totalement de manière isotrope, alors, la puissance reçue par le radar $P(r)$ s'écrirait :

$$P(r) = \frac{P_\sigma \cdot A_e}{4\pi r^2} = \frac{P_e \cdot G^2 \cdot \lambda^2}{(4\pi)^3 r^4} S(r) \quad (2.3)$$

Concrètement, on détecte toujours un grand nombre de cibles qui sont comprises dans le volume d'échantillonnage V approximativement défini par le produit de la section du faisceau par la longueur h correspondant à une impulsion telle que :

$$h = c \cdot \tau / 2 \quad (2.4)$$

Où τ est la durée d'une impulsion et c la vitesse de propagation de l'onde. Le volume d'échantillonnage est égal à :

$$V = \pi (r \cdot \theta / 2) (r \cdot \theta / 2) h. \quad (2.5)$$

Soit la section efficace de rétrodiffusion radar σ définie comme la surface d'une cible idéale réémettant toute l'énergie qu'elle intercepte de façon isotrope. Si l'on suppose que les cibles sont réparties uniformément dans le volume de résolution V , la section efficace volumique de rétrodiffusion radar $\eta(r)$ [$\text{m}^2 \text{m}^{-3}$], on l'appelle la réflectivité radar :

$$\eta(r) = \sum_i \sigma_i / V \quad (2.6)$$

L'équation du radar est alors :

$$P(r) = \left[\frac{P_e \cdot G^2 \cdot \lambda^2 \cdot \theta \cdot \phi \cdot h}{512 \cdot \pi^2 \cdot 2 \ln 2} \right] \frac{\eta(r)}{r^2} = C \cdot \frac{\eta(r)}{r^2} \quad (2.7)$$

2.6.3. Modèles de diffusion - Facteurs de réflectivité radar

Lorsqu'une onde électromagnétique interagit avec un corps dont les propriétés électriques diffèrent de celles du milieu environnant, une partie de l'énergie du champ incident est absorbée par le corps et apparaît sous forme de chaleur tandis que l'autre partie est diffusée dans toutes les directions. Dans le cas des précipitations, ce phénomène est décrit par l'application des équations de Maxwell à la diffusion d'une onde plane par une sphère homogène en milieu non absorbant. La théorie de Mie donne une solution générale à ce problème.

a) Diffusion de Mie

Pour les particules plus grosses que cette longueur d'onde, on doit prendre en compte la diffusion de Mie dans son intégralité : elle explique dans quelles directions la diffusion est la plus intense, on obtient ainsi un « patron de réémission » qui ressemble à celui des lobes d'émission d'une antenne, avec, dans le cas de grosses particules, un lobe plus intense dans la direction opposée à celle d'où provient l'onde incidente : couleur blanche des nuages.

b) Approximation de Rayleigh

La diffusion Rayleigh est un mode de diffusion des ondes, par exemple électromagnétiques ou sonores, dont la longueur d'onde est beaucoup plus grande que la taille des particules diffusantes. On parle de diffusion élastique, car cela se fait sans variation d'énergie, autrement dit l'onde conserve la même longueur d'onde : couleur bleue du ciel.

c) Facteur de réflectivité radar

Le facteur de réflectivité radar Z [$\text{mm}^6 \cdot \text{m}^{-3}$] est le moment d'ordre 6 de la distribution de gouttes $N_V(D)$ tel que :

$$Z = \int_0^\infty N(D) \cdot D^6 \cdot dD \quad (2.8)$$

Où la distribution de gouttes $N(D) \cdot dD$ représente le nombre de gouttes dont le diamètre D (mm) est compris entre D et $D+dD$ par unité de volume (m^3) d'air. Il est très utilisé car simplement proportionnel à la réflectivité radar dans le cadre de l'approximation de Rayleigh. On alors :

$$\eta = \int_0^\infty N(D) \cdot \sigma_R(D) \cdot dD = \frac{\pi^5}{\lambda^4} |K_W|^2 Z \quad (2.9)$$

Le coefficient K_W , appelé constante de normalisation de la réflectivité radar : $|K_W|^2 = 0.93$

Il est donc pratique d'utiliser une échelle logarithmique, avec comme unité le décibel dBZ :

$$Z[\text{dBZ}] = 10 \log (Z[\text{mm}^6 \cdot \text{m}^{-3}]) \quad (2.10)$$

2.6.4 Influence de la longueur d'onde sur les mesures radar

Les radars les plus courants opèrent à des fréquences allant d'environ 5 MHz à 95 GHz. Devant un spectre de fréquences aussi large, il est évident que les technologies utilisées, leurs aptitudes et leurs applications sont très différentes selon la fréquence à laquelle le radar opère. Des lettres ont été choisies pour désigner les différentes bandes de fréquences utilisées (voir Table 2.4).

Bandes	S	C	X	Ku	K	Ka	Q	U	V	W
Fréquences GHz	2-4	4-8	8-12	12-18	18-26	26-40	30-50	40-60	46-56	56-100
Longueurs d'ondes	15-7,5 cm	7,5-3,75 cm	3,75-2,5 cm	2,5-1,6 cm	16,6-11,5 mm	11,5-7,5 mm	10-6 mm	7,5-5 mm	6,5-5,3 mm	5,3-3 mm
Utilisation	Précipitations/Nuages en phase liquide/ Nuages de glace épais						Nuages de glace			

Table. 2.4 Lettres utilisées pour la désignation des bandes de fréquence radar

2.6.5. Atténuation des ondes électromagnétiques par les hydrométéores

Le coefficient d'atténuation dû aux hydrométéores est égal à la somme rapportée à l'unité de volume des atténuations dues à chaque hydrométéore. Il dépend donc de la distribution des hydrométéores $N(D)$ selon :

$$k = \int_0^{\infty} N(D) \sigma_e(D) dD \quad (2.11)$$

où $\sigma_e(D)$ représente l'atténuation due à un hydrométéore de diamètre D et s'appelle la section efficace d'extinction [m^2]. L'atténuation d'une onde électromagnétique est due à son absorption mais aussi à sa diffusion dans toutes les directions par les hydrométéores : $\sigma_e(D) = \sigma_a(D) + \sigma_d(D)$ où $\sigma_a(D)$ et $\sigma_d(D)$ sont les sections efficaces d'absorption et de diffusion des hydrométéores.

2.6.6 Atténuation des ondes électromagnétiques par la pluie

Le taux de précipitations ou le flux de précipitation est exprimé par R (mm. h⁻¹) en fonction de la distribution de gouttes

$$R = 6\pi \cdot 10^{-4} \int_0^{\infty} D^3 \cdot v(D) \cdot N_V(D) \cdot dD \quad (2.12)$$

Où $N_V(D) \cdot dD$ représente le nombre de gouttes dont le diamètre D (mm) est compris entre D et $D+dD$ par unité de volume (m³) d'air, et $v(D)$ est la vitesse de chute des gouttes.

Une loi de puissance permet de relier l'atténuation aux taux de précipitation telle que :

$$k = cR^d \quad (2.13)$$

où c et d sont des constantes qui dépendent de la longueur d'onde et de la température.

➤ Relations (Z, k, R)

Z , k , et R sont des variables intégrales de la distribution volumétrique des gouttes N . On a alors :

$$Z = a \cdot R^b, \quad k = c \cdot R^d, \quad Z = e \cdot k^f \quad (2.14)$$

En particulier, de nombreuses paramétrisations de la relation R - Z ont été proposées dans la littérature. On cite classiquement :

- Pluie convective : $Z = 486 \cdot R^{1.37}$ [Jones 1956]. (2.15)

- Pluie stratiforme : $Z = 200 \cdot R^{1.6}$ [Marshall et al. 1955]. (2.16)

- Neige : $Z = 1780 \cdot R^{2.21}$ [Sekhon et Srivastava 1970]. (2.17)




Fig. 2.26 Exemples de relations entre le taux de précipitation et l'atténuation pour les bandes K (0.86 cm), Ka (1.15 cm), X (3.2 cm), C (5.6 cm) et S (10 cm) et pour les températures $T = 0^{\circ}\text{C}$ (ligne pointillée), $T = 10^{\circ}\text{C}$ (ligne continue) et $T = 20^{\circ}\text{C}$ (ligne tirée) (Figure issue de [Delrieu et al. 2000]).

2.7. Conclusion

Nous avons présenté les différents dispositifs satellitaires utilisés en météorologie et principalement le satellite MSG ainsi que le radar météorologique. Ces dispositifs nous ont permis de collecter des images multispectrales de haute résolution et qui ont servi de base de données pour effectuer des tests sur la méthode que nous avons développée. Dans le chapitre suivant, nous allons décrire et faire une étude comparative des différentes approches de segmentation et de classification d'images satellitaires développées dans la littérature.

Chapitre 3

Méthodes de segmentation et de classification des images satellitaires

3.1 Préambule

L'imagerie multispectrale consiste à créer et à analyser des images de la même scène pour une succession de longueurs d'onde dans un domaine spectral donné. L'analyse et l'interprétation de telles images nécessitent généralement la réalisation d'une étape de classification dont l'objectif est de caractériser les individus (les pixels) en les regroupant en classes homogènes spectralement et en leur affectant éventuellement une étiquette sémantique (par exemple, type de nuages, caractéristique physique ou chimique ...). Pour ce faire, des méthodes de classifications classiques supervisées ou non telles que les k-means, fuzzy-c-means, classification hiérarchique, par graphe, ou encore de modélisation linéaire telles que la régression linéaire PLS(Partial Least Squares)[McDonald et al. 2003 ; Huang et al. 2004] ou non linéaires telles que les vecteurs supports (Support Vector Machine ou SVM) et les réseaux de neurones multicouches(MLP) sont ainsi largement utilisées, en télédétection.

Dans ce chapitre, nous présentons d'une part, les différentes approches de segmentation et de classification des images satellitaires en télédétection d'une manière générale, et d'autre part, nous montrons les différentes méthodes utilisées en météorologie. Et nous terminons par une étude comparative des différentes méthodes de classification qui nous a permis de justifier le choix de l'approche que nous avons adopté.

3.2 Stratégie de segmentation des images multispectrales

Pour traiter les images multi-composantes, trois stratégies peuvent être adoptées [Ouattara 2009] : marginale, scalaire et vectorielle. L'approche marginale consiste à segmenter chaque composante spectrale puis à fusionner les images segmentées en une seule image. L'approche scalaire procède d'abord à la fusion des différentes composantes spectrales en une seule composante, puis à la segmentation de cette dernière en la considérant comme une image en niveau de gris. Dans l'approche vectorielle, la segmentation est directement réalisée sur l'image multispectrale en utilisant une information vectorielle pour chaque pixel.

3.3 Approches de segmentation d'images

La segmentation fait référence aux notions de différence et de similarités perçues par le système visuel humain. Ces notions ont donné naissance à deux approches principales: l'approche frontière et l'approche région.

3.3.1 Approches contours

Les approches contours cherchent à extraire les contours présents dans l'image, en se basant sur l'étude des changements abrupts de la fonction de luminance ou sur la discontinuité des propriétés des ensembles. Les approches frontières peuvent aussi être classées en plusieurs catégories [Coquerez 1995], à savoir : les approches dérivatives [Deriche 1987 ; Fortier et al. 1999], morphologiques [Xue et al. 2003], et variationnelles. [Martinez et al. 2005 ; Rousson et Deriche 2002]. Toutes ces approches sont bien adaptées aux images qui présentent des régions uniformes au sens des niveaux de gris et offrent une bonne localisation spatiale. Mais, elles restent très sensibles aux bruits et aux contours mal définis. Ces méthodes sont appliquées pour détecter les frontières entre les objets mais ne s'appliquent pas aux frontières séparant des régions de textures différentes.

3.3.2 Approches régions

Les approches régions cherchent à détecter les zones de l'image présentant des caractéristiques d'homogénéité et vérifiant un critère d'homogénéité et de similitude. Parmi les

approches région, on distingue les méthodes de segmentation par seuillage, de croissance de régions, de division-fusion et de classification.

a. les méthodes de segmentation par seuillage

La segmentation par seuillage d'histogramme constitue un cas particulier de la segmentation par classification. Elle permet de répartir les pixels en classes en fonction de leurs niveaux de gris. Les classes sont alors délimitées par des seuils. Dans le cas des images multispectrales, l'application des histogrammes nécessite la combinaison des vallées des différents histogrammes [Roula et al. 2002; Cheng et Sun 2000].

b. Les méthodes de type croissance de régions

A partir d'un ensemble de points initiaux, cette méthode agrège les pixels selon deux critères: l'homogénéité et l'adjacence. Cette agrégation de pixels est contrôlée par un prédicat (fonction booléenne) [Ikonomakis et al. 2000 ; Voisine 2002]. Le processus s'applique sur une ou plusieurs régions. Le prédicat permet d'identifier une contrainte que doivent satisfaire les régions, il peut être de nature géométrique (région rectangulaire, région convexe ...), de nature radiométrique (région homogène,...) ou une combinaison des deux.

Exemples de prédicats d'homogénéité pour une région :

- La variance $\sigma^2(R)$ des niveaux de gris de l'image associés aux points de la région R est inférieure à un seuil préfixé.
- La proposition $\alpha(R)$ de points dont le niveau de gris se situe hors de l'intervalle : $[m(R) - \alpha(R), m(R) + \alpha(R)]$ (où $m(R)$ est la valeur moyenne des niveaux de gris), ne dépasse pas un seuil préfixé.

c. Les méthodes de type division-fusion

Après une étape d'initialisation, le processus de segmentation est itératif et alterne deux phases : une phase de division de toutes les régions non homogènes et une phase de fusion de toutes les régions adjacentes de sorte que la région résultante respecte toujours le critère

d'homogénéité [Tremeau et Colontini 2000]. Ces méthodes font appel à la théorie des graphes pour fusionner les régions adjacentes. Plusieurs approches de segmentation par division ont été investies : approche quad-tree [Baillie 2005] et algorithme de partage des eaux [Li et Xiao 2007].

d. Les méthodes de classification

Les classes sont construites à partir des attributs des pixels. Chaque pixel est affecté à une classe unique. Deux types d'approches peuvent être distinguées : les classifications non supervisées sans aucune connaissance a priori sur les données, et les classifications supervisées qui nécessitent une étape d'apprentissage préalable à la classification.

:

3.4 Approches d'analyse de la texture

Le terme texture s'utilise pour caractériser l'aspect visuel de la surface d'un objet. Cette notion est de ce fait très utilisée en analyse d'images. En effet, pour distinguer, dans une image, deux zones différentes qui ont la même intensité de gris, il est utile de s'intéresser aux motifs caractérisant ces deux zones. L'analyse de texture regroupe un ensemble de techniques mathématiques permettant de quantifier les différents niveaux de gris présents dans une image en termes d'intensité ou de rugosité et leur distribution. La diversité des images ainsi que la difficulté de donner une définition précise de la texture ont aussi permis l'émergence de plusieurs méthodes d'analyse de la texture qu'on peut classer essentiellement en trois approches [Mather et al. 1998] :

- Approche déterministe (structurelle).
- Approche spatio-fréquentielle.
- Approche stochastique ou statistique.

3.4.1 Approches structurelles

Les méthodes structurelles cherchent à extraire des primitives des textures et leurs localisations. Ces méthodes s'avèrent donc adaptées aux macrotextures, où une structure spatiale forte se dégage par l'intermédiaire d'un motif plus ou moins répétitif. Principalement, ces méthodes utilisent des techniques d'autocorrélation pour retrouver le placement des primitives

des textures initialement extraites, afin d'en déduire une règle de placement. Le trait caractéristique de ces méthodes est que toutes se déroulent en deux étapes, l'extraction de la primitive puis la recherche de la règle de placement [Beil 1999].

3.4.2 Approches spatio-fréquentielles

Dans les méthodes spatio-fréquentielles, les représentations préservent à la fois les informations globales et locales, elles sont donc bien adaptées aux signaux quasi périodiques. En effet, les textures sont des signaux quasi périodiques qui ont une énergie fréquentielle localisée. Ces méthodes permettent de caractériser la texture à différentes échelles [Rui et al. 1999].

Parmi les méthodes spatio-fréquentielles, on peut citer :

- La transformée de Fourier, sans doute la plus connue [Matsuyama et al.1983 ; D'hondt 2006].
- Les filtres de Gabor considérés comme des filtres précurseurs dans le domaine des méthodes de filtrage spatio-fréquentiel [Buf 1989 ; Tsai et al. 2005].
- La transformation en ondelettes [Mallat 1989 ; Ouma et Tateishi 2005].

3.4.3 Approches statistiques

L'approche statistique utilise le domaine spatial et prend en compte l'aspect statistique de la texture dans les procédures d'analyse, puisqu'on considère que la texture ne comporte pas des contours forts et ne possède pas un motif de base isolable, mais qu'elle a, au contraire, un comportement aléatoire. Elle consiste alors à évaluer, comme information texturale, les propriétés statistiques d'une région ou d'un certain voisinage autour d'un pixel. Cette approche est ainsi adaptée aux microtextures et a fait l'objet de plusieurs recherches qui ont donné naissance à un nombre considérable de méthodes [Haralick 1979 ; Zucker 1976]: elle est beaucoup utilisée dans l'analyse des images texturées.

Parmi les approches statistiques, on peut citer :

- Les attributs du premier ordre basés sur l'histogramme des intensités ;
- Les attributs du second ordre basés sur la corrélation des niveaux de gris de deux pixels en fonction de leurs positions dans l'image ;
- les attributs d'ordre supérieur basés sur les interactions entre plusieurs pixels.

D'autres approches qui ne font pas appel directement aux propriétés statistiques du niveau de gris, coexistent avec les méthodes citées ci-dessus. Elles exploitent plutôt les informations statistiques des images issues de certaines transformations que l'on a fait subir à l'image de la texture considérée. Dans cette catégorie, on peut citer :

- Le modèle fractal basé essentiellement sur l'estimation de la dimension fractale (mesure du degré d'irrégularité d'un objet) de la surface décrite par la fonction du niveau de gris de l'image [Kpalma 1992 ; Myint 2003] ;
- la procédure des chemins aléatoires [Wechsler et Kidode 1979; Efros et Freeman 2001] ;
- L'analyse multirésolution [Peleg et al. 1987 ; Akono et al. 2003] ;
- La méthode des extréma locaux [Mitchell et al. 1977 ; Trias 2006] ;
- La méthode de l'intégrale curviligne [Barba et al. 1985] ;

a. Méthodes de premier ordre

L'analyse de texture par les méthodes de premier ordre se fait au niveau de pixels individuels d'une région de l'image à traiter. Les paramètres tels que la moyenne, la variance, l'entropie, etc.... sont calculés à partir de l'histogramme des intensités.

b. Méthodes de second ordre

L'une des méthodes les plus utilisées est celle des matrices de cooccurrences ou méthode de dépendance spatiale des niveaux de gris appelée aussi SGLDM (Spatial Gray Level Dependence Method) introduite par Haralick [Haralick.1979]. Elle permet de déterminer la fréquence d'apparition d'un motif formé de deux pixels séparés par une distance dans plusieurs directions.

Plusieurs travaux ont montré que les matrices de cooccurrences contiennent une information texturale importante qui améliore la discrimination des classes, plus particulièrement en télédétection. Quatorze paramètres descriptifs des textures, tels qu'ils sont définis par Haralick [Haralick.1979] peuvent être extraits à partir de la matrice de cooccurrence. Parmi ceux-ci, nous avons retenu les plus fréquemment utilisés en télédétection [Kayitakire et al. 2002 ; Ameur et al. 2001 ; Gu et al. 1991]: l'énergie, l'entropie, contraste, corrélation, directivité, homogénéité locale et uniformité.

c. Méthodes d'ordre supérieur

Elles étudient les interactions plusieurs pixels. Comme dans le cas des méthodes de second ordre, l'information extraite à partir des voisinages locaux des pixels de l'image. Les matrices de plage constituent un exemple de ce type de méthodes [Galloway. 1975].

3.4.4 Approche basée sur les vecteurs de Rangs

Les vecteurs de rangs ont pour effet d'éliminer beaucoup de configurations par rapport à l'utilisation directe des niveaux de gris. Néanmoins, l'information locale reste insuffisante du fait du nombre de pixels utilisés pour le codage. La méthodologie de codage des rangs et d'évaluation de leur fréquence d'apparition consiste à affecter une valeur de code à chaque pixel de l'image, et non un niveau de gris. Le codage peut être considéré comme une approche symbolique du traitement d'images. En effet, l'image d'origine représentée dans l'espace de départ, est transformée en une image codée dans un espace intermédiaire de façon à ce que l'information texturale soit mise en évidence. L'image symbolique obtenue dans l'espace intermédiaire permet ensuite d'extraire les caractéristiques de la texture [Ameur et al. 2006].

3.4.4.1 Méthodologie


Dans le cas du 4-Voisinage d'un pixel $P(i,j)$, le vecteur de niveaux de gris est donné par :

$V = (P(i-1,j), P(i,j-1), P(i,j+1), P(i+1,j))$ en fonction de 4 labels $\alpha_i = i$ ($i = 0$ à 3) affectés aux différents pixels voisins à $P(i,j)$. (Voir figure 3.1 (a),(b)).

Les labels α_i sont ensuite arrangés selon l'ordre croissant des niveaux de gris correspondants et forment ainsi les composantes du vecteur de rang $V_R (r_0, r_1, r_2, r_3)$ (figure 3.1(c)).

Le code du pixel $P(i,j)$ correspondant au vecteur de rangs V_R est donné par l'équation (3.1). (Voir figure 3.1(d))

$$C(i,j) = r_0 \cdot 4^0 + r_1 \cdot 4^1 + r_2 \cdot 4^2 + r_3 \cdot 4^3 \quad (3.1)$$



(a) 4-Voisinage

40	20	255	50
0	1	2	3

(b) Vecteur de niveau de gris

1	0	3	2
---	---	---	---

(c) Vecteur de Rang

$$C(i,j) = 1 \cdot 4^0 + 0 \cdot 4^1 + 3 \cdot 4^2 + 2 \cdot 4^3 = 177$$

(d) Code du pixel $P(i,j)$

Fig. 3.1 Codage et calcul des vecteurs de rangs selon le 4-Voisinage

Les différentes combinaisons des 4 labels $\alpha_{i=0 \text{ à } 3} = i$ conduisent à 24 vecteurs de rangs. Chaque vecteur de rangs V_{Ri} correspond à un modèle M_i (Voir Table 3.1).

Le paramètre de texture de chaque pixel est alors un vecteur de 24 composantes $(N_1, N_2, \dots, N_{24})$ Où chaque valeur N_i correspond à la fréquence d'apparition du modèle M_i dans une fenêtre d'analyse de taille $n \times n$ pixels centrée en $P(i,j)$.

Cette méthode initialement élaborée pour un 4-voisinage, peut être étendue à un 8-voisinage (rang 2x2) et un 16-voisinage (rang 2x4), ceci afin de tenir compte de l'anisotropie de la texture [Ameur et al. 2006].

Vecteurs de rangs $V_R (r_0 r_1 r_2 r_3)$	Codes des pixels (C)	Modèles
(3 2 1 0)	27	M_1
(2 3 1 0)	30	M_2
(3 1 2 0)	39	M_3
(1 3 2 0)	45	M_4
(2 1 3 0)	54	M_5
(1 2 3 0)	57	M_6
(3 2 0 1)	75	M_7
(2 3 0 1)	78	M_8
(3 0 2 1)	99	M_9
(0 3 2 1)	108	M_{10}
(2 0 3 1)	114	M_{11}
(0 2 3 1)	120	M_{12}
(3 1 0 2)	135	M_{13}
(1 3 0 2)	141	M_{14}
(3 0 1 2)	147	M_{15}
(0 3 1 2)	156	M_{16}
(1 0 3 2)	177	M_{17}
(0 1 3 2)	180	M_{18}
(2 1 0 3)	198	M_{19}
(1 2 0 3)	201	M_{20}
(2 0 1 3)	210	M_{21}
(0 2 1 3)	216	M_{22}
(1 0 2 3)	225	M_{23}
(0 1 2 3)	228	M_{24}

Table 3.1 Vecteurs de rangs, Modèles et Codes des pixels selon le 4-Voisinage

3.5 Méthodes de classification d'images multispectrales

La classification est l'élaboration d'une règle de décision qui transforme les attributs caractérisant les formes en appartenance à une classe (passage de l'espace de codage vers l'espace de décision). La classification des données satellites dépend de nombreux facteurs relatifs à la thématique de l'étude, aux besoins de l'utilisateur, aux caractéristiques de la zone d'étude, à la disponibilité, aux caractéristiques et à la qualité des données satellites. Les étapes de

classification incluent le choix des images satellites, la détermination de la méthode de classification appropriée, les opérations de prétraitement des images, la sélection des échantillons d'apprentissage et enfin l'évaluation de la classification [Lefsky et Cohen 2003; Olthof et Fraser 2007; Simonneaux et al. 2008].

Il existe différentes méthodes de classification qui peuvent être réparties selon deux types de critère à savoir : Supervisée ou non supervisée et paramétrique ou non paramétrique.

L'approche est supervisée lorsque des informations à priori sont introduites dans la phase de construction des classes, et nécessite une phase d'apprentissage à partir d'échantillons dont les classes sont connues. La classification est dite non-supervisée lorsqu'aucune connaissance à priori n'est disponible. Par ailleurs, les méthodes paramétriques sont des approches de classification statistiques dont les lois de probabilités des classes sont supposées connues (classification bayésienne, méthode du maximum de vraisemblance, champs de Markov). En revanche, les méthodes sont non paramétriques si aucune distribution statistique n'est exploitée (K means, c-fuzzy means, méthode du parallélépipède, les Machines à Support Vecteurs (SVM) et les réseaux neuronaux).

3.5.1 Classification par la méthode du parallélépipède (hypercubes)

Cette méthode supervisée basée sur une logique booléenne. Des données d'entraînement dans b bandes spectrales sont utilisées pour effectuer la classification. Pour chaque classe C , on calcule le vecteur $\mu_C = (\mu_{c_1}, \dots, \mu_{c_d})$ où μ_{c_k} représente le niveau de gris moyen des pixels de la classe C dans la bande k .

σ_{c_k} est l'écart type des données d'entraînement de la classe C dans la bande k . Si on utilise un seuil égal à σ_{λ_k} , l'algorithme du parallélépipède affecte un pixel de vecteur de mesures $X = (x_{ij_1}, \dots, x_{ij_b})$ à la classe C , si et seulement si l'équation suivante est satisfaite :

$$\mu_{c_k} - \sigma_{c_k} < x_{ij_k} < \mu_{c_k} + \sigma_{c_k}, \forall k \in [1 \ b] \quad (3.2)$$

b : représente le nombre de bandes et x_{ij_k} est la valeur radiométrique du pixel (i,j) dans la bande k . Par conséquent, si les frontières de décision inférieure et supérieure sont définies

respectivement par $L_{c_k} = \mu_{c_k} - \sigma_{c_k}$ et $H_{c_k} = \mu_{c_k} + \sigma_{c_k}$, la règle de décision du parallélépipède devient :

$$L_{c_k} < x_{ijk} < H_{c_k}, \forall k \in [1 \ b] \quad (3.3)$$

Ces règles de décision forment un parallélépipède multidimensionnel dans l'espace des caractéristiques. Si la valeur du pixel est comprise entre la borne inférieure L et la borne supérieure H pour les « d » bandes évaluées pour une classe donnée, alors il est affecté à cette classe, et dans le cas contraire il est affecté à une catégorie non classée. La figure 3.2 illustre le cas à deux dimensions.

Le recours à cette méthode nécessite une excellente connaissance des objets à classer et par conséquent, les aires d'entraînement doivent être choisies avec beaucoup de soin pour être les plus représentatifs possibles de la dynamique spectrale de chacun d'eux.

Comme toute classification, cette méthode a des inconvénients qui sont :

- l'existence des pixels non classés ;
- le problème de la superposition des boîtes : cette méthode peut entraîner des confusions lorsque les signatures de certaines classes spectrales se chevauchent.

3.5.2 Classification par minimisation de distance

Le principe des méthodes reposant sur la minimisation de distance consiste à chercher la classe la plus proche pour chaque pixel, ou groupe de pixels si l'on travaille dans une fenêtre d'analyse centrée sur le pixel courant. La notion de proximité est liée à la distance considérée.

Ces méthodes sont en général non-supervisées et ne requièrent pas de phase d'apprentissage, relativement simples à mettre en œuvre, et Leur vitesse de convergence est relativement élevée. Pour ce type de classifications, plusieurs outils sont disponibles, comme les K plus proches voisins, K-means et Fuzzy-C-means.

3.5.2.1 Classification par la méthode des K plus proches voisins

La méthode des k plus proches voisins (k nearest neighbours, k -NN) est une méthode de classification supervisée, non paramétrique dont le principe est d'affecter un pixel « x » à la classe majoritaire des k plus proches voisins de la base d'apprentissage. La proximité des pixels est déterminée par un calcul de distance euclidienne ou Mahalanobis dans l'espace des paramètres. Les performances de la méthode dépendent du choix de la valeur de k . Différents algorithmes de classification de données de télédétection par les k -NN ont été développés dans la littérature [Nuzillard et Lazar 2007 ; Voisine 2002].

3.5.2.2 Méthode des K -means

C'est une méthode non supervisée qui 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 [Moghriani 2007]. C'est une méthode qui a pour objectif de partitionner l'espace des attributs en k classes (k connu). A partir d'une partition initiale on améliore itérativement la partition de l'espace en minimisant la variance intra-classe.

L'algorithme des k -means est donné ci-dessous :

$X=(x_i)$ ensemble de N échantillons de l'espace métrique Ω et d la distance associée. x_i est le vecteur paramètre du pixel i .

- 1) Phase d'initialisation : On affecte des valeurs de départ aux centroïdes $(\mu_j)_{1 \leq j \leq k}$ des k classes. Les méthodologies d'initialisation sont multiples. On peut, par exemple, choisir d'initialiser les centroïdes à des positions occupées par des éléments de x choisis au hasard. D'autres stratégies d'initialisation ont également été envisagées [Arthur et Vassilvitskii 2007]. Pour chaque échantillon x_i , $(\mu'_i)_{1 \leq i \leq N}$ représente le centroïde le plus proche calculé à partir de l'équation (3.5). L'énergie initiale E_o ($t=0$) est calculée à partir de la relation suivante :

$$E_0 \leftarrow \sum_{i=1}^N \frac{1}{2} d(x_i, \mu'_i)^2 \quad (3.4)$$

Répéter

2) Itération suivante : $t \leftarrow t + 1$

3) Mise à jour des classes : Chaque x_i est affecté à la classe dont le centroïde est le plus proche à partir de l'équation suivante:

$$\mu'_i \leftarrow \arg \min_{\mu_j} d(x_i, \mu_j) \quad \text{pour } 1 \leq i \leq N \quad (3.5)$$

4) Mise à jour des centroïdes des k classes : On évalue chaque centroïde μ_j comme la moyenne des x_i qui ont été affectés à la classe S_j :

$$\mu_j = \text{moyenne} (x_i, \text{tels que } \mu'_i = \mu_j) \quad \text{pour } 1 \leq j \leq k \quad (3.6)$$

5) Calcul de l'énergie totale :

$$E_t \leftarrow \sum_{i=1}^N \frac{1}{2} d(x_i, \mu'_i)^2 \quad (3.7)$$

Jusqu'à $E_t = E_{t-1}$

3.5.2.3 Classification par ISODATA

C'est une variante de l'algorithme des K-means, cet algorithme, nommé "Iterative Self-Organizing Data Analysis Technics" ISODATA [Ball et Hall 1965], autorise, au cours des itérations, la fusion entre de nuages proches, la division d'un nuage à variance élevée et la suppression de nuage de petite taille.

L'utilisateur doit spécifier donc les paramètres suivants :

- Le nombre minimum de membres dans un segment n_{min} . Si un segment contient moins de membres que le minimum spécifié, il est supprimé et ses membres sont affectés à un autre segment.
- L'écart type maximum σ_{max} . Lorsque l'écart type d'un segment dépasse le maximum spécifié, et que le nombre de membres est deux fois supérieur au minimum de membres spécifiés dans une classe, le segment est divisé en deux régions.

- La distance minimum entre les segments d_{min} . Des segments ayant une distance pondérée inférieure à cette valeur sont fusionnés.

3.5.2.4 Classification par Fuzzy-C-means

L'approche C-moyennes flous (Fuzzy-C-Means ou FCM) [Bezdek 1981] est une méthode de classification floue non supervisée qui permet de segmenter une image en régions spectralement homogènes sans toutefois prendre en compte les relations spatiales entre pixels. Dans le cas d'une image contenant n pixels à partitionner en c classes, chacun des n individus appartient à chacune des c classes, avec un coefficient d'appartenance u , u_{ik} étant le degré d'appartenance de l'individu k à la classe i .

d_{ki}^2 est la distance entre l'individu k et la classe i tel que :

$$d_{ki}^2(x_k, v_i) = \|x_k - v_i\|_A^2 = (x_k - v_i)A(x_k - v_i)^T \quad (3.8)$$

Où A est une matrice symétrique définie positive et v_i le prototype de la classe i .

Soit U la matrice des coefficients u_{ik} et V celle des coordonnées des centres des classes, l'objectif de l'algorithme est de trouver U et V minimisant une fonction de coût définie de la façon suivante :

$$J = \sum_{k=1}^n \sum_{i=1}^c u_{ik}^m d^2(x_k, v_i) \quad (3.9)$$

Sous les contraintes suivantes :

$$u_{ik} \in [0,1], \sum_{i=1}^c u_{ik} = 1, \forall k, \quad 0 < \sum_{k=1}^n u_{ik} < n \quad \forall i \quad (3.10)$$

(m) est un paramètre permettant de contrôler le degré de flou de la partition. En général, ce paramètre vaut 2.

Une solution pour la minimisation de la fonction d'objectif J peut être obtenue par une procédure itérative où les centres des classes v_i et les degrés d'appartenance de la donnée x_k aux i classes (u_{ik}) en cours sont mis à jour via les équations suivantes :

$$u_{ik} = \frac{1}{\sum_{j=1}^c \left(\frac{d_{ik}}{d_{ij}} \right)^{\frac{2}{m-1}}} \quad (3.11)$$

$$v_i = \frac{\sum_{k=1}^n u_{ik}^m \cdot x_k}{\sum_{k=1}^n u_{ik}^m} \quad (3.12)$$

De nombreuses approches permettant d'introduire une contrainte spatiale dans l'algorithme des C-moyennes floues ont été proposées dans la littérature. Parmi les plus récentes, on peut notamment citer celles de [Bandyopadhyay 2005 ; Chuang et al. 2006 ; Wang et Fei, 2008].

3.5.3 Classification par la méthode du maximum de vraisemblance

La classification par le maximum de vraisemblance (Maximum Likelihood) est une méthode paramétrique supervisée qui minimise l'erreur de classification en se basant sur des lois de probabilité. Dans un premier temps, on calcule la probabilité de chaque pixel de l'image d'appartenir à une classe à partir des vérités terrain. Par la suite, le pixel est affecté à la classe pour laquelle la probabilité est la plus élevée.

a) Notations

Une image est constituée d'un ensemble S de sites s_i ou pixels. Soit K l'ensemble des classes parmi lesquelles on choisit les étiquettes de chaque pixel. Une classe sera notée C_i .

L'espace des états est noté E , sa dimension est égale au nombre de critères sélectionnés.

Soient :

- y_s le vecteur de E associé au site s de l'image S .
- N est la dimension de E .
- $y = (y_{s_1}, \dots, y_{s_{|S|}})$.
- x_s la classe dans K attribuée à s .
- $x = (x_{s_1}, \dots, x_{s_{|S|}})$.

Avec :

Y_s est le processus aléatoire associé à y_s .

Y est le processus aléatoire associé à y .

X_s est le champ aléatoire associé à x_s .

X est le champ aléatoire associé à x .

b) Hypothèse gaussienne

On suppose l'hypothèse suivante : Pour chaque classe c_i , la loi de probabilité $P(y_s/x_s = c_i)$ est gaussienne.

Par ailleurs, chaque classe c_i est définie par un vecteur moyenne μ_i et une matrice de covariance Σ_i dans l'espace des états E . L'apprentissage consistera à approximer les statistiques de chaque classe par les statistiques sur les régions d'apprentissage correspondantes. On calculera donc les vecteurs moyennes et les matrices de covariance dans l'espace des états, pour chacune des classes comme suit :

$$\Sigma_i = \begin{bmatrix} \text{var}(x_1) & \text{cov}(x_1, x_2) & \cdots & \text{cov}(x_1, x_j) & \cdots & \text{cov}(x_1, x_N) \\ \text{cov}(x_1, x_2) & \text{var}(x_2) & \cdots & \text{cov}(x_2, x_j) & \cdots & \text{cov}(x_2, x_N) \\ \vdots & \vdots & \vdots & \vdots & \vdots & \vdots \\ \text{cov}(x_1, x_j) & \text{cov}(x_2, x_j) & \cdots & \text{var}(x_j) & \cdots & \text{cov}(x_j, x_N) \\ \vdots & \vdots & \vdots & \vdots & \vdots & \vdots \\ \text{cov}(x_1, x_N) & \text{cov}(x_2, x_N) & \cdots & \text{cov}(x_j, x_N) & \cdots & \text{var}(x_N) \end{bmatrix} \quad (3.13)$$

La covariance entre deux vecteurs x_1 et x_2 ainsi que la variance de chaque vecteur x_j sont données respectivement par les équations (3.14) et (3.15).

$$\text{cov}(x_1, x_2) = \frac{1}{N} \sum_{i=1}^N [(x_{1i} - \bar{x}_1) \cdot (x_{2i} - \bar{x}_2)] \quad (3.14)$$

$$\text{Var}(x_j) = \frac{1}{N} \sum_{i=1}^N (x_{ij} - \bar{x}_j)^2 \quad (3.15)$$

c) Ecriture du problème

Sous ces deux hypothèses, nous cherchons à déterminer la meilleure classification des pixels de l'image x_{opt} définit comme suit :

$$x_{opt} = \arg \max_x P(X = x / Y = y) \quad (3.16)$$

D'après la règle de Bayes, on peut écrire :

$$x_{opt} = \arg \max_x P(Y = y / X = x) P(X = x) \quad (3.17)$$

D'où

$$x_{opt} = \arg \max_x \prod_s P(Y_s = y_s / X_s = x_s) \quad (3.18)$$

Le problème global est donc ramené à un problème d'optimisation local, grâce à l'hypothèse d'indépendance conditionnelle des pixels.

$$x_{s\ opt} = \arg \max_{x_s} P(Y_s = y_s / X_s = x_s) \quad (3.19)$$

Et sous l'hypothèse gaussienne, on obtient l'équation suivante :

$$x_{s\ opt} = \arg \max_{\lambda_i \in K} \frac{\exp\left(-\frac{1}{2}(y_s - \mu_i)^T \cdot (\Sigma_i)^{-1} \cdot (y_s - \mu_i)\right)}{\det(\Sigma_i)^{1/2} \cdot (2\pi)^{N/2}} \quad (3.20)$$

où N est la dimension de l'espace des états, soit le nombre de critères choisis. Pour des raisons pratiques, on préférera calculer le logarithme de l'expression ci-dessus.

$$x_{s\ opt} = \arg \min_{\lambda_i \in K} ((y_s - \mu_i)^T \cdot \left(\sum_i\right)^{-1} \cdot (y_s - \mu_i) + \log \det\left(\sum_i\right)) \quad (3.21)$$

3.5.4 Classification contextuelle par les champs de Markov

Les champs de Markov (Markov random field, MRF) sont largement utilisés en imagerie scalaire ou multispectrale pour traiter des problèmes de classification, de segmentation ou encore de régularisation. La classification markovienne est une méthode statistique supervisée qui exploite la notion de voisinage et la notion de dépendance locale des pixels voisins. Ainsi, les MRF permettent la prise en compte des interactions locales entre chaque site (pixel) avec les pixels voisins pour définir les différentes régions de l'image. Après une introduction aux notions de base des champs de Markov, nous ferons une brève revue de quelques approches disponibles dans la littérature et utilisant les champs de Markov pour le traitement des images multispectrales.

3.5.4.1 Champs de Markov

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

$$P(X_s = x_s / X^s = x^s) = P(X_s = x_s / x_t, t \in V_s) \quad (3.22)$$

Cela 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. Ainsi, tout l'intérêt d'une modélisation Markovienne réside donc dans la possibilité de spécifier localement un modèle qui est en fait global.

3.5.4.2 Equivalence entre champs de Gibbs et de Markov

Le théorème de Hammersley-Clifford permet d'assimiler le champ de Markov à une distribution de Gibbs [Li, 1995] dont la formulation énergétique d'écrit alors :

$$P(X = x) = \frac{1}{Z} \exp(-U(x)) = \frac{1}{Z} \exp(-\sum_{c \in C} U_c(x)) \quad (3.23)$$

Où Z est une constante appelée fonction de partition permettant de normaliser la distribution $P(X)$. $U(x)$ est appelée fonction d'énergie et C est l'ensemble des cliques associées au voisinage V .

$U(x)$ peut prendre diverses formes, pour un champ de Markov de voisinage 4-connexe, nous pouvons écrire l'énergie de la configuration x sous la forme $U(x) = \sum_{c=(i) \in C_1} U_c(x_i) + \sum_{c=(i,j) \in C_2} U_c(x_i, x_j)$ où C_1 et C_2 sont respectivement les cliques d'ordre 1 et d'ordre 2




Fig. 3.3 Représentation des cliques suivant le système de voisinage

Le modèle de Potts est une généralisation du modèle d'Ising. Il est bien adapté au problème de classification des images (labellisation). Dans ce modèle, les potentiels d'ordre 1 (terme d'attache aux données) permettent de caractériser l'adéquation des étiquettes aux observations. Les potentiels d'ordre 2, appelés encore terme contextuel ou modèle a priori, introduisent un effet régularisant sur le champ des étiquettes. Ils sont calculés par la fonction $U_c(s,t)$ telle que :

$$U_{c=(s,t)}(x_s, x_t) = \begin{cases} -\beta & \text{si } x_s = x_t \\ +\beta & \text{si } x_s \neq x_t \end{cases} \quad \text{avec } \beta \geq 0 \quad (3.24)$$

Ainsi, un voisinage non identique engendre une augmentation du potentiel et ainsi à une diminution de la probabilité, ce qui revient à privilégier l'établissement de voisinages

homogènes. Le modèle gaussien Markovien est réservé aux images en niveaux de gris. Le voisinage est 4 ou 8 connexe et la fonction de potentiel $U(x)$ est de la forme suivante :

$$U(x) = \beta \sum_{c=(s,t)} (x_s - x_t)^2 + \alpha \sum_{s \in S} (x_s - \mu_s)^2 \quad (3.25)$$

Le premier terme est un terme de régularisation qui favorise les faibles différences de niveaux de gris entre sites voisins pour $\beta > 0$. Le second terme est un terme d'attache aux données. Le traitement suivant consiste à rechercher la réalisation d'image de probabilité maximale à l'aide de procédures itératives : recuit simulé, ICM (Iterated Conditional Mode).

3.5.4.3 Recherche de la configuration la plus probable

L'objectif est de trouver la configuration optimale, celle qui maximise la probabilité, donc qui minimise l'énergie.

Le recuit simulé (simulated annealing) a été initialement proposé par Kirkpatrick [Kirkpatrick et al. 1982] et repris par Geman et Geman [Geman et Geman, 1984] est un algorithme inspiré d'un processus utilisé en thermodynamique. Ce processus alterne des cycles de refroidissement lent et de réchauffage (recuit) qui tendent à minimiser l'énergie du matériau, dans notre cas, cela correspond à obtenir les extrema de la fonction d'énergie. Le recuit simulé permet de sortir d'un minimum local.

Malheureusement, l'algorithme du recuit simulé est très lourd en temps de calcul puisqu'il demande la génération d'un grand nombre de configurations au fur et à mesure que la température décroît. Des algorithmes sous-optimaux sont donc souvent utilisés en pratique.

Besag [Besag 1986] a ainsi proposé un autre algorithme, beaucoup plus rapide. Il s'agit de l'ICM, Iterated Conditional Mode, c'est un algorithme itératif modifiant de façon déterministe à chaque étape les valeurs x_s de l'ensemble des sites de l'image.

3.5.4.4 Application des Champs de Markov dans la classification des images

Soit y une image que nous pouvons considérer comme une réalisation d'un champ aléatoire Y . Nous cherchons une réalisation x de l'image classée, que nous pouvons modéliser comme un champ de Markov, où X est le champ des étiquettes (labels). La classification a pour objectif de remonter à une réalisation de X à partir de l'observation des données y . On parle alors de champ de Markov caché pour X , ou de données incomplètes puisque y n'est pas une réalisation de X .

$$P(X = x / Y = y) = \frac{P(Y=y/X=x).P(X=x)}{P(Y=y)} \quad (3.26)$$

On suppose l'indépendance conditionnelle des pixels d'où la relation suivante :

$$P(Y = y / X = x) = \prod_s P(Y_s = y_s / X_s = x_s) \quad (3.27)$$

Le champ X est supposé markovien, on déduit alors l'équation suivante :

$$P(X = x / Y = y) = K. \exp (-W(x/y)) \quad (3.28)$$

Où K est une constante et $W(x/y)$ est l'énergie du champ de Markov donnée comme suit :

$$W(x / y) = \sum_{s \in S} -\ln P(y_s / x_s) + \sum_{c \in C} U_c(x) \quad (3.29)$$

$P(X/Y)$ est une distribution de Gibbs et donc un champ de Markov (théorème de Hammersley-Clifford).

➤ La classification

Le champ markovien X est défini sur un autre espace de configurations que Y car seules quelques étiquettes sont considérées : $E = \{1, \dots, m\}$ correspondant aux différentes classes cherchées).

Les valeurs des probabilités conditionnelles sont données par l'histogramme conditionnel des niveaux de gris pour une classe donnée. Si on suppose que chaque classe i a une distribution gaussienne de moyenne μ_i et d'écart-type σ_i , on a :

$$P(y_s / x_s = i) = \frac{1}{\sigma_i \sqrt{2\pi}} \exp \left(-\frac{(y_s - \mu_i)^2}{2\sigma_i^2} \right) \quad (3.30)$$

En télédétection la probabilité conditionnelle $P(Y/X)$ est donnée par l'équation (3.20).

La probabilité $P(X=x)$ a priori permet d'introduire les contraintes que nous souhaitons imposer à la solution. On se limite fréquemment aux cliques d'ordre 2, on a :

$$P(X = x) = \frac{1}{Z} \exp \left(-\beta \sum_{(s,t) \in C_2} \phi(x_s, x_t) \right) \quad (3.31)$$

Avec $\phi(x_s, x_t) = -1$ si $x_s = x_t$ et $\phi(x_s, x_t) = +1$ si $x_s \neq x_t$.

On calcul alors l'énergie $W(x/y)$ comme suit :

$$W(x / y) = \sum_s \frac{(y_s - \mu_{x_s})^2}{2\sigma_{x_s}^2} + \ln(\sigma_{x_s} \sqrt{2\pi}) + \beta \sum_{(s,t) \in C_2} \phi(x_s, x_t) \quad (3.32)$$

La constante β pondère l'influence entre le terme d'attache aux données (cliques d'ordre 1) qui impose des niveaux de gris x_s de l'image classée, proches de y_s , et le terme qui exprime la contrainte de régularisation introduite (cliques d'ordre 2) et qui impose une solution constituée de zones homogènes. On choisit souvent un modèle de Potts pour X , ce qui donne une image classée avec de larges zones homogènes. La fonction ϕ modélise les potentiels des cliques d'ordre 2 : $U_{c=(s,t)} = \phi(x_s, x_t)$.

La classification de l'image Y revient à déterminer le champ de Markov X qui minimise l'énergie $W(x / y)$ en appliquant les algorithmes : Recuit simulé ou ICM.

3.5.5 Machines à Support Vecteurs

Les machines à vecteurs supports ou séparateurs à vaste marge (Support Vector Machine, SVM) sont un ensemble de techniques d'apprentissage supervisé destiné à résoudre des problèmes de discrimination et de régression et sont particulièrement adaptées pour traiter les données de hautes dimensions [Vapnik 1998]. Elles sont basées sur des propriétés géométriques (frontières) des ensembles à discriminer plutôt qu'à leurs propriétés statistiques. Les SVM ont été utilisées dans de nombreux domaines (reconnaissance de forme, imagerie médicale...) mais également dans le traitement des images hyperspectrales où elles ont donné des résultats

encourageants [Karimi et al. 2006 ; Melgani et Bruzzone 2004 ; Roli et Fumera 2001 ; Gualtieri et Chettri 2000].

3.5.5.1 Principe de base des SVM

Les approches SVM consiste à rechercher la séparation optimale entre deux classes.

Soit X un ensemble de N exemples d'apprentissage dont chaque élément est représenté par $(\vec{x}_i, y_i)$ avec $i = 1$ à N , y_i un label de classe pouvant prendre la valeur $+1$ ou -1 et $\vec{x}_i$ un vecteur de paramètres). L'objectif d'un classifieur est de déterminer, à partir des données d'apprentissage, une fonction de décision : $g(x, \alpha) \rightarrow y$ (avec α paramètres du classifieur).

Dans le cas d'un classifieur linéaire, la fonction g peut être définie à l'aide d'un hyperplan d'équation $\vec{w} \cdot X + b = 0$ (où $\vec{w}$ et b désignent les paramètres de l'hyperplan). La classification d'un vecteur $\vec{x}_i$ est alors donnée par le signe de la fonction g , donc $y_i = +1$ si $\text{signe}[g(\vec{x}_i)] > 0$ ou $y_i = -1$ si $\text{signe}[g(\vec{x}_i)] < 0$.

Les vecteurs supports sont situés sur deux hyperplans parallèles (H_1 et H_2) à l'hyperplan optimal d'équation $\vec{w} \cdot X + b = 0$ et ont pour équation respective $\vec{w} \cdot X + b = -1$ et $\vec{w} \cdot X + b = +1$ (figure 3.4).

Les exemples d'apprentissage ne doivent pas être dans la marge, d'où les équations suivantes :

$$\begin{cases} \vec{w} \cdot \vec{x}_i + b \geq +1 & \text{si } y_i = +1, \\ \vec{w} \cdot \vec{x}_i + b \leq -1 & \text{si } y_i = -1 \quad \forall i = 1, \dots, N \end{cases} \quad (3.33)$$

La distance entre les deux hyperplans $H1$ et $H2$ est $d = \frac{2}{\|\vec{w}\|}$. Maximiser cette marge revient donc à minimiser $\frac{1}{2} \|\vec{w}\|^2$ sous les contraintes : $y_i(\vec{w} \cdot \vec{x}_i + b) - 1 \geq 0$

Ceci peut se résoudre par la méthode classique des multiplicateurs de Lagrange, où le lagrangien est donné par :

$$L(w, w_0, \alpha) = \frac{1}{2} \|\vec{w}\|^2 - \sum_{i=1}^N \alpha_i \{ y_i(\vec{w} \cdot \vec{x}_i + b) - 1 \} \quad (3.34)$$

Le lagrangien doit être minimisé par rapport à w et w_0 , et maximisé par rapport à α .

En utilisant le principe de dualité et multiplicateurs de Lagrange, le vecteur $\vec{w}^*$ réalisant l'optimum peut s'écrire sous la forme $\vec{w}^* = \sum_{i=1}^N \alpha_i^* y_i \vec{x}_i$. Les α_i^* sont les multiplicateurs de Lagrange déterminés et sont non-nuls uniquement pour les points $\vec{x}_i$ se trouvant sur les vecteurs supports. Le paramètre b^* est déterminé à partir d'un exemple d'apprentissage.

Après le calcul des paramètres α^* et b^* , la classification d'une nouvelle observation $\vec{x}$ est déterminée par le signe de $(\sum_{j \in \text{vs}} y_j \alpha_j^* \vec{x} \cdot \vec{x}_j + b^*)$.

3.5.5.2 Cas non linéairement séparable

Dans le cas où les échantillons d'entraînement ne sont pas linéairement séparables, on introduit une fonction Φ permettant de projeter les données dans un espace de dimension supérieure (D) linéairement séparables (voir figure 3.5) :

$$\begin{cases} R^d \rightarrow R^D & \text{avec } D \gg d \\ \vec{x} \rightarrow \Phi(\vec{x}) \end{cases} \quad (3.35)$$

On recherche dans ce nouvel espace, l'hyperplan optimal donné comme suit :

$$g^*(\vec{x}) = \vec{w}^* \cdot \Phi(\vec{x}) + b^* \quad (3.36)$$

$$\text{D' où} \quad g^*(\vec{x}) = \sum_{i=1}^n \alpha_i y_i \Phi(\vec{x}_i) \cdot \Phi(\vec{x}) + b^* \quad (3.37)$$

Ainsi, la seule connaissance des produits scalaires entre les points est suffisante pour calculer la fonction g^* . La représentation de $\Phi(\vec{x})$ n'est donc pas nécessaire. Il suffit déterminer une fonction noyau (k) tel que :

$$k(\vec{x}_i, \vec{x}_j) = \Phi(\vec{x}_i) \cdot \Phi(\vec{x}_j) \quad (3.38)$$

Vapnik [Vapnik, 1998] a montré que toute fonction satisfaisant les conditions de Mercer peut être utilisée comme noyau.




Fig. 3.4 L'hyperplan optimal est perpendiculaire au segment de droite le plus court joignant un exemple d'apprentissage à l'hyperplan.

Parmi les noyaux les plus utilisés pour la classification des images satellitaires [Gualtieri et Chettri 2000 ; Huang et al. 2002 ; Camps-Valls et al. 2006a] on trouve : le noyau gaussien

$$k(x, y) = \exp\left(-\frac{\|x-y\|^2}{2\sigma^2}\right), \text{ le noyau polynomial } k(x, y) = (x \cdot y + I)^p.$$

Des noyaux adaptés aux images satellitaires et utilisant des relations contextuelles ont été proposées par divers auteurs dont Mercier [Mercier et al., 2003], Camps-Valls [Camps-Valls et al. 2006b] ou encore Fauvel [Fauvel, 2007, Fauvel et al., 2007].




Fig. 3.5 Changement d'espace de représentation par noyau

3.5.6 Réseaux de neurones

Un réseau de neurones artificiels est un modèle de calcul dont la conception est inspirée du fonctionnement des neurones biologiques. C'est un modèle statistique basé sur le principe de l'apprentissage [Rosenblatt 1958].

Le réseau de neurones est constitué d'un ensemble de neurones interconnectés par des poids. Durant la phase d'apprentissage, le réseau détermine la relation statistique optimale entre les données d'entrée et de sortie en modifiant les poids à attribuer à chaque liaison entre les neurones. Contrairement aux méthodes traditionnelles, dans la classification de données, les réseaux de neurones permettent de traiter des problèmes non structurés sur lesquels on ne dispose d'aucune information au préalable.

Les premiers modèles de réseaux de neurones comportaient de nombreuses limitations [Minsky et Papert 1969], mais avec l'apparition du "perceptron multicouche" (multi-layer perceptron), leur application s'est généralisée dans le domaine de la classification [Hornik et al. 1989].

3.5.6.1 Les perceptrons multicouches

Le principe de fonctionnement des perceptrons multicouche est schématisé à la figure 3.7. Ces systèmes sont composés de minimum trois couches de neurones : une couche d'entrée, plusieurs couches cachées et une couche de sortie. Chaque neurone d'une couche est connecté à tous les neurones de la couche précédente et de la couche suivante. Il n'existe, par contre, pas de liaison au sein d'une même couche. Soit o_i la sortie du neurone i . Le neurone j est connecté aux

L neurones de la couche précédente et reçoit leur sorties via les liaisons pondérée par les poids w_{ji} . Le neurone j reçoit donc le signal d'activation a_j :

$$a_j = \sum_{i=1}^L w_{ji} o_i + w_{j0} \quad (3.39)$$

où w_{j0} est le terme de biais du neurone j . Ce terme peut être vu comme la contribution d'un neurone 0 connecté à tous les autres et dont la sortie vaut 1 (Voir figure 3.6).

La sortie du neurone j est donnée par la fonction de transfert f_j appelée fonction d'activation par la relation suivante :

$$O_j = f_j(a_j) \quad (3.40)$$




Fig. 3.6 Structure d'un neurone caché ou de sortie




Fig. 3.7 Structure d'un réseau de neurones à 3 couches.

Pour que le réseau de neurones puisse résoudre des problèmes non-linéaires, la fonction de transfert f_j doit être non-linéaire. On utilise généralement une fonction sigmoïde définie par :

$$f: \mathbb{R} \rightarrow [0 \ 1] : f(a_i) = \frac{1}{1+e^{-a_i}} \quad (3.41)$$

Les réseaux de neurones permettent d'associer de façon non linéaire des entrées et des sorties. En effet, le nombre de neurones de la première couche correspond au nombre d'attributs, le nombre de neurones de la couche de sortie est égal au nombre de classes. Quant à la couche cachée le nombre de neurones est déterminé pendant la phase d'apprentissage. En générale, les entrées sont normalisées de sorte que ses valeurs soient comprises entre 0 et 1.

La modélisation par réseaux de neurones est réalisée en trois phases :

- Construction d'une base d'apprentissage (sélection de paires entrées-sorties). Cette base de données doit être la plus représentative possible.
- Apprentissage du réseau de neurones par ajustement des différents poids de connexion : Cette phase nécessite un ensemble de données pertinentes pour établir des classifications fiables.
- Généralisation du modèle qui consiste à évaluer la performance du réseau avec une base de données différente de celle d'apprentissage.

3.5.6.2 Apprentissage par rétropropagation du gradient

L'apprentissage du réseau de neurones consiste à déterminer les valeurs des poids permettant d'optimiser la relation entre les données en entrée et en sortie. Cet apprentissage s'effectue grâce à la minimisation d'une fonction de coût calculée à partir des exemples de la base d'apprentissage et de la sortie du réseau de neurones. Nous avons effectué cette minimisation par un algorithme de descente du gradient.

La fonction de coût la plus utilisée est l'erreur quadratique sur la base d'apprentissage qui consiste à minimiser la somme des carrés des erreurs entre la sortie désirée du réseau et la valeur réelle de la sortie définie comme suit :

$$E = \frac{1}{2} \sum_k (d_k - O_k)^2 \quad (3.42)$$

Où d_k et O_k sont respectivement la sortie désirée et calculée du neurone k .

Soit un Réseau à 3 couches (voir Figure 3.8) tel que :

- Couche d'entrée : m unités notées i
- Couche cachée : n neurones notés j
- Couche de sortie : p neurones notés k



Fig. 3.8 Réseau à 3 couches

On peut alors écrire pour chaque neurone j de la couche cachée:

$$a_j \leftarrow \sum_{i=0}^m x_i w_{ji} \quad ; \text{ avec } x_0 = 1 \text{ (Biais)} \quad (3.43)$$

$$y_j \leftarrow \frac{1}{1 + e^{-a_j}} \quad (3.44)$$

Et pour chaque neurone k de la couche de sortie :

$$a_k \leftarrow \sum_{j=0}^n y_j w_{kj} \quad ; \text{ avec } y_0 = 1 \text{ (Biais)} \quad (3.45)$$

$$O_k \leftarrow \frac{1}{1 + e^{-a_k}} \quad (3.46)$$

Le principe de l'algorithme de rétropropagation par descente de gradient est la recherche du minimum de la fonction E dans l'espace des poids par annulation des dérivées partielles (voir Figure 3.9) .

$$\vec{w} \leftarrow \vec{w} + \Delta \vec{w} \quad \text{avec} \quad \Delta \vec{w} = -\eta \nabla E [\vec{w}] \quad (3.47)$$

Avec η est le pas de descente ou d'apprentissage et $\nabla E [\vec{w}]$ est le gradient de l'erreur E .

$$\text{d'où} \quad \vec{w} \leftarrow \vec{w} - \eta \nabla E [\vec{w}] \quad (3.48)$$

➤ Pour la couche de sortie on peut écrire :

$$\frac{\partial E}{\partial w_{kj}} = \delta_k y_j \quad (3.49)$$

$$\text{Avec} \quad \delta_k = -O_k(1 - O_k)(d_k - O_k) \quad (3.50)$$

D'où

$$\Delta w_{kj} = -\eta \frac{\partial E}{\partial w_{kj}} = -\eta \delta_k y_j \quad (3.51)$$

➤ Pour la couche cachée on a :

$$\frac{\partial E}{\partial w_{ji}} = \delta_j x_i \quad (3.52)$$

Avec

$$\delta_j = \frac{\partial E}{\partial y_j} \cdot \frac{\partial y_j}{\partial a_j} \quad (3.53)$$

Et

$$\frac{\partial E}{\partial y_j} = \sum_{k=0}^p \delta_k w_{kj} \quad (3.54)$$

A partir de la propriété de la fonction sigmoïde on a :

$$\frac{\partial y_j}{\partial a_j} = y_j (1 - y_j) \quad (3.55)$$

d'où
$$\delta_j = y_j (1 - y_j) \sum_{k=0}^p \delta_k w_{kj} \quad (3.56)$$

Et
$$\Delta w_{ji} = -\eta \frac{\partial E}{\partial w_{ji}} = -\eta \delta_j x_i \quad (3.57)$$




Fig. 3.9 Illustration de la descente de gradient

Nous utiliserons pour l'apprentissage du réseau de neurone MLP l'algorithme de rétropropagation avec minimisation du gradient d'erreur qui est défini par les étapes suivantes [Caloz et Collet, 2001].

1. Initialiser les poids du réseau.
2. Insérer à l'entrée du réseau une observation (exemple) de la base de données en forme de vecteur de caractéristiques, puis calculer sa valeur d'activation et sa fonction d'activation en utilisant les formules (3.59) et (3.60).

$$a_i = \sum_j w_{ij} o_j \quad (3.58)$$

$$f(a_i) = \frac{1}{1 + e^{-a_i}} \quad (3.59)$$

3. Pour chaque unité de sortie k , calcul de δ_k et Δw_{kj} :

$$\delta_k \leftarrow -O_k(1 - O_k)(d_k - O_k) \quad (3.60)$$

$$\Delta w_{kj}(t) = -\eta \delta_k y_j \quad (3.61)$$

4. Pour chaque unité cachée j , calcul de δ_j et Δw_{ji} :

$$\delta_j = y_j (1 - y_j) \sum_{k=0}^p \delta_k w_{kj} \quad (3.62)$$

$$\Delta w_{ji}(t) = -\eta x_i \delta_j \quad (3.63)$$

5. Ajuster les poids w_{kj} et w_{ji} à l'instant t comme suit :

$$w_{kj}(t) = w_{kj}(t - 1) + \Delta w_{kj}(t) \quad (3.64)$$

$$w_{ji}(t) = w_{ji}(t - 1) + \Delta w_{ji}(t) \quad (3.65)$$

6. Répéter les étapes 2 à 5 pour l'ensemble des observations de la base d'apprentissage tant que le critère d'arrêt n'a pas été atteint.

La convergence du réseau de neurones dépend des valeurs de η . En effet, si la valeur de η est trop petite la convergence est trop lente. En revanche, si la valeur est trop grande alors les poids oscillent et ne se stabilisent pas. Ainsi, on commence avec une grande valeur de η , puis on diminue progressivement.

Par ailleurs, afin de prévenir les oscillations, augmenter la vitesse de convergence et empêcher la convergence vers un minimum local, on ajoute un coefficient α appelé (Inertie ou Momentum) dans le calcul de Δw dont l'équation à l'instant t est donnée comme suit :

$$\Delta w_{ji}(t) = -\eta \frac{\partial E}{\partial w} + \alpha \Delta w_{ji}(t - 1) \quad (3.66)$$

Avec $0.1 < \alpha < 0.8$, la valeur typique est $\alpha = 0.6$

➤ Critères d'arrêts

L'algorithme de rétropropagation du gradient est donc répété à chaque itération t . Si pour tous les exemples, le coût est inférieur à un seuil choisi, on dit alors que le réseau a convergé. Mais selon ce critère, l'apprentissage peut être long avant de converger. C'est pourquoi on emploie aussi d'autres critères d'arrêt de l'apprentissage tels que:

- le nombre maximum de périodes d'apprentissage (nombre de pas de l'algorithme);
- la variation absolue du coût (E) entre les périodes t et $t+1$. Cette variation absolue, selon Haykin (1994), doit être petite, typiquement entre 0,1% et 1%. La valeur la plus utilisée est 0,1%;
- le critère hybride de Kramer et Sangiovanni-Vincentelli (1989). Celui-ci porte sur la norme du vecteur gradient qui doit être inférieure à un gradient seuil ε suffisamment petit;
- le critère utilisant la généralisation [Haykin, 1994]. Après chaque période d'apprentissage, le réseau est testé pour sa performance à généraliser, à la façon de la validation croisée c'est-à-dire, on teste le réseau sur de nouvelles observations ne faisant pas partie de l'ensemble d'apprentissage. Le processus d'apprentissage est stoppé lorsque la performance à généraliser est adéquate selon l'expérimentateur. Cette performance à généraliser se mesure en calculant l'erreur entre la réponse désirée et la réponse obtenue en utilisant de nouvelles observations. Dans le cas de la classification, la performance à généraliser se mesure en déterminant l'erreur de classification qui est le fait de se tromper sur la classe exacte d'une observation.

Dans une situation pratique, le critère d'arrêt de l'apprentissage est choisi par rapport à l'objectif et aux analyses subséquentes envisagées.

➤ Nombre de neurones de la couche cachée

L'inconvénient des réseaux à couches est le manque d'éléments théoriques permettant de relier d'une part le nombre de couches cachées et le nombre de neurones par couche et d'autre part le type et la complexité du problème à traiter. Il existe des équations empiriques pour

déterminer le nombre maximal de neurones dans une couche cachée. La formule (3.68) nous montre une heuristique pour déterminer ce nombre.

$$N_c \leq 2.N_e + 2 \quad (3.67)$$

où

N_e est le nombre d'entrées du MLP.

N_c est le nombre entier de neurones cachés.

Généralement pour déterminer le nombre neurones dans la couche cachée, le concepteur doit effectuer un grand nombre d'expériences. Par exemple, on fait varier la taille du réseau puis on effectue un apprentissage complet pour chaque taille et enfin on choisit la structure qui conduit aux meilleurs résultats.

3.6 Etude comparative des méthodes de classification en télédétection

On utilise une classification non supervisée ou automatique lorsque l'identité des classes n'est pas connue. Cela résulte d'un manque d'information ou de l'incertitude sur la réalité du terrain. Les méthodes les plus utilisées en télédétection sont : K means, Isodata et C-fuzzy means. Ces méthodes sont itératives, facile à implémenter et convergent rapidement. Les résultats de classification dépendent du choix initial des centres des classes, du nombre de classe et du critère d'appartenance à une classe (Distance). De plus, l'interprétation des classes obtenues est souvent difficile à réaliser. Parmi ces trois méthodes la C-fuzzy means est la plus performante dans la classification des images de télédétection.

Si l'utilisateur possède suffisamment d'informations sur le terrain étudié pour constituer une nomenclature, il peut effectuer une classification supervisée. Pour cela, il doit au préalable définir des sites d'entraînement ou d'apprentissage correspondant à des régions homogènes et dont on connaît la nature. Ces méthodes sont généralement plus performantes que les approches non supervisées. Les plus utilisées en télédétection sont : Hypercube, maximum de vraisemblance, k-NN, champs de Markov, SVM et Réseau de neurones.

La méthode des k-NN (k plus proches voisins) est une méthode directe de classification supervisée qui ne nécessite pas une étape d'apprentissage. En effet, il suffit de disposer d'échantillons pertinents de chaque classe et d'affecter chaque pixel de l'image à la classe la plus proche selon la distance euclidienne ou de Mahalanobis. De plus, elle est facile à implémenter et donne de bons résultats de classifications. Cependant, le résultat dépend du choix de k ainsi que des échantillons représentatifs des classes.

D'autre part, La classification par hypercube sépare les classes par des hypercubes localisés par des valeurs minimales et maximales de chaque composante dans l'espace des paramètres. Cette méthode est simple à implémenter et donne de bons résultats de classification si la base de données est constituée d'échantillons pertinents, et que les seuils de chaque classe sont choisis de sorte que les hypercubes ne se chevauchent pas.

Par ailleurs, l'algorithme du maximum de vraisemblance prend en considération la covariance des classes spectrales lors de l'affectation des pixels. Il définit des contours de forme ellipsoïdale dans l'espace radiométrique qui maximisent les chances de bonne classification. Cette méthode donne de meilleurs résultats que les méthodes des hypercubes et des K-NN. Cependant les performances de la méthode dépendent du choix des échantillons représentatifs des classes.

Les méthodes basées sur les champs de Markov sont supervisées et exploitent la dimension spatiale (Information contextuelle) qui joue un rôle prépondérant en analyse visuelle. Elles permettent souvent de tracer avec une bonne précision les contours d'une zone malgré l'hétérogénéité spectrale des pixels qui la composent. Cependant, ces méthodes ont comme inconvénients : Difficultés d'implémentation et lourdeur algorithmique.

Les approches SVM donnent de bons résultats de classification pour des images ayant un nombre importants d'attributs comme le cas des images hyperspectrales. De plus, les résultats sont meilleurs pour les cas de discrimination entre deux classes. Par contre, l'introduction d'une contrainte spatiale au travers la définition du noyau ne permet pas de maîtriser parfaitement la notion spatiale. Les SVM sont toutefois des approches supervisées qui nécessitent de choisir les exemples d'apprentissage certes en nombre limité mais de façon très rigoureuse.

D'autre part, les réseaux de neurones peuvent approximer n'importe quelle fonction [Hornik et al. 1989]. En particulier, les perceptrons multicouches (MLP) permettent la résolution

de problèmes non-linéaires tels que ceux rencontrés dans le domaine des sciences atmosphériques [Del Frate et al. 2002 ; Müller et al. 2003]. De plus, les réseaux de neurones ne nécessitent pas la connaissance a priori des lois de probabilité des classes comme c'est le cas des méthodes statistiques. De plus, une fois entraînés, ces algorithmes possèdent également une rapidité d'exécution beaucoup plus grande que les autres approches tels que : SVM , champs de Markov et fuzzy-C-means.

3.7 Conclusion

La robustesse d'une méthode de classification dépend d'une part du type d'attributs extraits des images, et d'autre part du choix du classifieur. A partir de l'étude comparative des différentes approches développée dans le paragraphe précédent, l'approche supervisée par réseaux de neurone semble la mieux adaptée pour notre travail de recherche. En effet, l'utilisation du radar nous a permis de construire une base de données pertinentes et représentatives des différentes classes de nuages précipitants : convectives et stratiformes. Ainsi, cette base de données nous a permis de réaliser la phase d'apprentissage et de validation de notre modèle d'identification et de classification des nuages précipitants. La méthodologie de notre approche fera l'objet du chapitre suivant.

Chapitre 4

Approche adoptée pour l'identification et la classification des nuages précipitants

4.1 Préambule

La détection et l'analyse des nuages précipitants est une phase importante pour l'estimation des paramètres météorologiques tels que le taux de précipitation. Différentes méthodes de segmentation et de classification des images satellitaires ont été publiées dans la littérature. Ces méthodes sont soit non supervisées basées sur des approches tels que : les Fuzzy c-means [Satyanarayana et Srinivas 2011], les K-means [Zahraie et Roozbahani 2011], ou supervisées basées sur les approches tels que: les SVM [Jain et Bhatia. 2013; Lee et al. 2004], le Maximum de vraisemblance [Feidas et Giannakos 2011 ; Thies et al. 2008a , 2008b, 2010] et les Réseaux de neurones [Giannakos et Feidas 2013 ; Sehad et al. 2014a].

Dans ce chapitre nous présentons tout d'abord la méthode ECST [Reudenbach et al. 2001] qui est la technique de référence utilisée dans la littérature pour comparer les résultats de classification des nuages précipitants en convectifs et stratiformes. Ensuite, nous présentons la méthode RACT-DN [Sehad et al. 2014b] d'identification et de classification des nuages précipitants jour et nuit que nous avons élaborée. Notre approche est appliquée au nord de l'Algérie en exploitant les données du satellite météorologique MSG. Notre approche est basée sur des caractéristiques spectrales, texturales et temporelles. La classification est réalisée par une méthode supervisée en appliquant deux réseaux de neurones multicouches MLP, l'un pour le jour et l'autre pour la nuit. L'apprentissage des deux réseaux est réalisé par des données collectées par radar (radar de Sétif). Après une présentation du site d'étude et des données utilisées, nous détaillons la méthodologie de notre approche basée d'une part, sur l'identification des nuages

précipitants, et d'autre part, sur la classification de ces nuages en convectifs et stratiformes. Enfin, nous analysons les résultats obtenus et les comparons aux résultats obtenus par Radar et par la méthode de référence ECST.

4.2. Présentation du site d'étude et des données utilisées

4.2.1. Présentation du site

L'Algérie est un pays sud méditerranéen situé au nord-ouest du continent africain et au centre du Maghreb. Bordée au nord par la Méditerranée avec près de 1200 km de côtes, l'Algérie est enchâssée entre sept pays: le Maroc et le Sahara Occidental à l'ouest, la Mauritanie, le Mali et le Niger au sud et la Libye et la Tunisie à l'est. La zone d'étude est située au Nord de l'Algérie s'étend sur environ 800 km de long et 400 km de large (figure 4.1). Cette zone est couverte par 219 pluviomètres sur les 320 implantés sur le territoire algérien.



Fig. 4. 1. Région d'étude qui coïncide avec la couverture du Radar de Sétif d'un rayon de 250 km.

4.2.2. Données utilisées

Nous avons exploité des données collectées par le satellite MSG et par le radar de Sétif. Cette base de données est divisée en deux parties : La première est constituée d'images collectées durant la période de novembre 2006 à Mars 2007 et contenant 2109 scènes de

précipitations qui sont utilisées dans la phase d'apprentissage de l'approche élaborée. La deuxième base de données est constituée d'images prises pendant la période de Novembre 2010 à Mars 2011 et composée de 1936 scènes de précipitations utilisées pour la phase de validation.

a. Données du satellite MSG

Les données satellite utilisées dans ce travail sont issues du radiomètre SEVIRI du satellite MSG. Le radiomètre SEVIRI fournit 12 images dans les 12 canaux disponibles toutes les 15 minutes. Pour notre étude, nous avons sélectionné les canaux suivants : VIS0.6, NIR1.6, IR3.9, WV6.2, WV7.3, IR8.7, IR10.8 et IR12.0. L'image provenant du satellite MSG est de type (Level 1.5) de taille de 3712×3712 pixels pour tous les canaux [Eumetsat 2004]. La résolution spatiale du centre de l'image est de 3 km² et chaque pixel est codé sur 10 bits. De plus, le point sub-satellite est localisé à 3.5°E de longitude et 0° de latitude qui correspond au pixel de la position (1856, 1856) sur l'image. En utilisant l'image (Level 1.5) et les coefficients de calibration, nous avons calculé la radiance de chaque pixel. Ainsi, la valeur de chaque pixel de l'image initiale (Level 1.5) appelée « count », est convertie en radiance (exprimée en mWm⁻²sr⁻¹(cm⁻¹)⁻¹) à l'aide de l'équation (4.1) [Eumetsat 2004] :

$$Ra(i, ch) = CN(i, ch) . slope(ch) + offset(ch) \quad (4.1)$$

Où $CN(i, ch)$ (valeurs possibles entre 0 et 1023) est le compte numérique d'un pixel i pour un canal ch . Les paramètres $offset(ch)$ et $slope(ch)$ sont des coefficients de calibration exprimés en mWm⁻²sr⁻¹cm⁻¹ utilisés pour calculer la radiance à chaque pixel d'un canal ch , dont les valeurs sont données à l'entête de chaque image [Eumetsat 2004]. La valeur de radiance peut ensuite être convertie en température de brillance dans les canaux infrarouges et en réflectance dans les canaux visibles [Eumetsat 2004]. Ainsi, pour chaque pixel, la température de brillance Tb (kelvin) dans les canaux infrarouges est calculée à partir de la formule de Planck (4.2) [Voir Annexe A].

$$Tb = \frac{c_2 \cdot v_c}{\left(\log\left(\frac{c_1 \cdot v_c^3}{Ra} + 1\right) - B \right) \cdot A} \quad (4.2)$$

Où $c_1 = 1,19104 \cdot 10^{-5} mWm^{-1}sr^{-1}(cm^{-1})^{-4}$ et $c_2 = 1,43877K(cm^{-1})^{-1}$

ν_c est le nombre d'onde central du canal d'observation par cm.

A et B sont deux paramètres d'ajustement dépendant du canal (voir Table 4.1).

N° de canal	Canal	ν_c	A	B
4	IR3.9	2569.094	0.9959	3.471
5	WV6.2	1598.566	0.9963	2.219
6	WV7.3	1362.142	0.9991	0.485
7	IR8.7	1149.083	0.9996	0.181
8	IR9.7	1034.345	0.9999	0.060
9	IR10.8	930.659	0.9983	0.627
10	IR12.0	839.661	0.9988	0.397
11	IR13.4	752.381	0.9981	0.576

Table.4.1 Valeurs des constantes, A et B en fonction des canaux infrarouges.

La réflectance Re (%) est calculée pour les canaux ($VIS0.6$, $VIS0.8$, $NIR1.6$, HRV) à partir de l'équation suivante :

$$Re = \frac{\pi \cdot Ra \cdot d^2(t)}{I \cdot \cos(\theta(t,x))} \cdot 100 \quad (4.3)$$

Où Ra est la radiance du pixel calculée par l'équation (4.1), $d(t)$ est la distance terre-soleil à l'instant t (calculée en fonction de la date), I est une constante dépendant du canal d'observation (voir table 4.2), et $\theta(t,x)$ est l'angle zénithale solaire (calculé en fonction de la date, temps, latitude et longitude).

N° du Canal	1 (VIS0.6)	2 (VIS0.8)	3 (NIR1.6)	12 (HR0.7)
I	65.2296	73.0127	62.3715	78.8952

Table 4.2. Valeurs de la constante I en fonction du canal

b. Données du radar météorologique de Sétif

L'Algérie dispose de sept Radars météorologiques dont celui de Sétif situé à la position $36^\circ 11' N$, $5^\circ 25' E$ et à 1 700 m d'altitude. C'est un Radar AWSR 81C en bande C, sa fréquence

opérationnelle est de 5.6 GHz. Le déplacement en azimuth est entre 0 à 360 degrés continus et le déplacement en inclinaison de -20° à 90° . Sa polarisation est linéaire et horizontale.

Les images radar utilisées sont collectées à une résolution temporelle de 15 min et une résolution spatiale de 1km^2 sous un format de 512×512 pixels. Chaque pixel est codé sur 4 bits. Cela correspond à 16 classes (figure 4.2). Les caractéristiques techniques du radar sont données par la table suivante :

Paramètres	Radar de Sétif
Longueur d'onde (cm)	5.5
Puissance crête (kw)	250
Fréquence de répétition (Hz)	250
La durée de l'impulsion (μs)	4

Table 4.3. Caractéristiques du radar de Sétif

Le paramètre physique représentatif de l'image radar est le facteur de réflectivité noté (Z) exprimé en $(\text{mm}^6\text{m}^{-3})$. La conversion du facteur de réflectivité Z en intensité de précipitations R (mm/h) est obtenue par l'équation (4.4) adaptée à la situation météorologique de la région de notre étude.

$$Z = 300 \cdot R^{1.5} \quad (4.4)$$

Elle peut être aussi convertie en dBZ par la relation suivante:

$$Z(\text{dBZ}) = 10 \log (Z) \quad (4.5)$$

L'acquisition et le prétraitement des images radar sont réalisés à l'aide du système SANAGA (Système d'acquisition Numérique pour l'analyse des Grains Africains). Le SANAGA est un système d'acquisition des données radar développé au laboratoire d'Aérodologie de Toulouse [Sauvageot et Despaux 1990] et implanté sur de nombreux radars à travers le monde dont ceux du réseau algérien. Ce dispositif comprend essentiellement un module câblé de numérisation, un

micro-ordinateur et un logiciel interactif, travaillant en temps réel. La figure 4.2 représente une image enregistrée par le radar de Sétif en réflectivité (en dBZ).




Fig. 4. 2. Image en réflectivité issue du radar de Sétif.

- **Colocalisation des données Radar et Satellite**

Comme la résolution spatiale du Radar est différente de celle du satellite, les données radar de résolution $1 \times 1 \text{ km}^2$ ont été reprojctées et rééchantillonnées à la résolution spatiale des données MSG ($4 \times 5 \text{ km}^2$ dans la zone d'étude). De plus, on constate un décalage spatial entre ces deux types de données en raison des erreurs de parallaxe et des erreurs de collocation [Vicente et al. 2002]. En effet, le décalage de parallaxe est dû à l'angle d'observation de la terre par le radiomètre SEVERI. Ainsi, les nuages observés par SEVIRI peuvent subir un décalage de parallaxe jusqu'à 20 km par rapport aux images radar météorologique [Kühnlein et al. 2010]. D'autre part, l'erreur de parallaxe est fonction de la hauteur des nuages. Par conséquent, l'erreur est plus importante pour les nuages convectifs que pour les nuages stratiformes. Pour réduire ce décalage et trouver le maximum de corrélation entre les données radar et satellite, chaque pixel

radar a été comparé aux 5x5 pixels de l'image MSG pour le cas des nuages hauts et aux 3x3 pixels dans le cas des nuages bas.

4.3. La méthode Convective Stratiforme « Convective Stratiform Technique (CST) »

Les méthodes basées sur la mesure de la température de brillance au sommet des nuages dans l'infrarouge thermique (10-12 μ m) tels que [Griffith et al. 1978 ; Scofield et Oliver 1977 ; Carn et Lahuec 1987 ; Milford et Dugdale 1989 ; Arkin 1979 ; Gruber 1973] ne permettent d'estimer que les précipitations dues aux nuages convectifs sans tenir compte des nuages stratiformes. Néanmoins, plusieurs études ont montré que ces derniers peuvent contribuer à hauteur de 40 à 50% du total des précipitations observées pour certains systèmes nuageux [Houze et Happaport 1984]. C'est ainsi que Adler et Negri (1988) ont développé une méthode qui permet d'estimer les précipitations en tenant compte à la fois des nuages convectifs et des nuages stratiformes « CST ». Cette méthode qui utilise des données infrarouges du satellite GOES opère de la manière suivante :

- On localise dans l'image infrarouge tous les minima locaux ($T_{min(i,j)}$) de coordonnées i,j .
- On élimine les minima correspondant à des cirrus en utilisant une relation empirique. Pour ce faire, un paramètre de pente est calculé pour chaque température minimale $T_{min(i,j)}$. Le paramètre S est défini comme suit :

$$S = \bar{T}_{1-6} - T_{min} \quad (4.6)$$

Où $\bar{T}_{1-6}$ est la température moyenne des six pixels voisins du pixel de température $T_{min(i,j)}$. $\bar{T}_{1-6}$ est calculée par la relation suivante :

$$\bar{T}_{1-6} = (T_{i-2,j} + T_{i-1,j} + T_{i+1,j} + T_{i+2,j} + T_{i,j+1} + T_{i,j-1})/6 \quad (4.7)$$

- On établit une ligne de discrimination empirique de cirrus minces à partir de la relation **température/pente** en utilisant des données radar. Si les valeurs de T_{min} et sa pente se trouvent à gauche de la ligne de discrimination, le pixel de T_{min} est classé comme un

noyau convectif. Sinon le pixel est classé comme un cirrus (non précipitant). Notons qu'une valeur élevée de la pente implique une température très basse, le pixel correspond alors à un cumulonimbus.

- Un seuil T_s de 208 K est ensuite appliqué pour caractériser les zones stratiformes.

Cette technique a été appliquée avec succès dans les régions tropicales sur des systèmes convectifs [Bendix 1997, 2000]. Cependant, elle ne permet pas de discriminer d'une façon fiable la partie convective responsable des précipitations des cirrus qui sont également froids mais qui ne produisent pas de pluie. C'est ainsi que Reudenbach et al (2001) ont amélioré cette technique en ajoutant la différence positive de température de brillance entre le canal vapeur d'eau WV et le canal infrarouge IR de Météosat 7 afin d'éliminer les cirrus non précipitants. Cette différence positive de température de brillance ΔT_{WV-IR} est due à la présence de nuages dans la basse stratosphère transportés en altitude par la convection profonde [Fritz et Laszlo 1993; Tjemkes et al. 1997]. Cette méthode rebaptisée « Enhanced CST (ECST) » a été appliquée à des systèmes convectifs en moyennes latitudes [Reudenbach et al. 2001] et a permis d'améliorer sensiblement les résultats.

4.4. Méthodologie de l'approche développée d'identification et de classification des nuages précipitants RACT-DN

La méthode RACT-DN [Sehad et al. 2014b] que nous avons élaborée permet d'une part, de détecter les régions précipitantes, et d'autre part de classer les nuages précipitants en convectifs et stratiformes. Notre approche est basée sur deux réseaux de neurones multicouches, MLP-D pour le jour et MLP-N pour la nuit. Les paramètres d'entrée de chaque réseau correspondent aux caractéristiques spectrales, texturales et temporelles déterminés pour chaque pixel des images MSG. La couche de sortie de chaque réseau de neurones est constitué de 3 neurones qui correspondent aux trois classes : convectif, stratiforme et non précipitant. Nous avons utilisé pour l'apprentissage des réseaux de neurones MLP-D et MLP-N, les données du radar de Sétif qui nous permet de détecter les nuages convectifs et stratiformes. En effet, les pixels des images radar dont les réflectivités sont comprises entre 18 dBZ et 38 dBZ sont considérés comme stratiformes, et ceux dont la réflectivité est supérieure à 42 dBZ sont convectifs.

4.4.1. Paramètres spectraux

Les propriétés optiques et microphysiques des nuages (*CWP* et Phase des nuages) sont directement liées à la probabilité qu'un nuage soit précipitant et peuvent donc être utilisées comme un délimiteur entre les nuages précipitants et non précipitants [Nauss et Kokhanovsky 2006, 2007]. (Voir chapitre1, paragraphe 1.6).

Le paramètre *CWP* est donc directement lié à la probabilité qu'un nuage soit pluviogène. Cette hypothèse repose sur le fait que les particules assez grosses peuvent tomber contre le champ de vent ascendant au sein d'un nuage d'une extension verticale, qui favorise la croissance de ces particules [Lensky et Rosenfeld 2003a; Nauss et al. 2007].

De plus, la présence de particules de glace (phase des nuages) dans la partie supérieure de nuage renforce l'hypothèse qu'un nuage soit pluviogène suivant le processus Bergeron-Findeisen [Houze 1993].

Par conséquent, les attributs spectraux durant le jour et la nuit que nous avons utilisés pour notre méthode sont définis comme suit :

➤ Paramètres spectraux durant le jour

Pour identifier les nuages précipitants durant le jour, nous avons utilisé :

- La réflectance $VIS_{0.6}$ du canal $VIS0.6$ pour avoir des informations sur le rayon effectif des particules des nuages (figure 4.3(a)) .
- La réflectance $NIR_{1.6}$ du canal proche-infrarouge $NIR1.6$ pour avoir des informations sur l'épaisseur optique des nuages. On remarque sur la figure 4.3(a) que les grandes valeurs de probabilité de précipitation correspondent à de grandes valeurs de $VIS_{0.6}$ et de faibles valeurs de $NIR_{1.6}$. Ces valeurs correspondent alors à de grandes valeurs du paramètre *CWP*.

- La température de brillance $T_{10.8}$ du canal IR10.8 représente la température de brillance au sommet du nuage.
- Les différences de températures de brillances $\Delta T_{8.7-10.8}$ entre le canal IR8.7 et le canal IR10.8 et $\Delta T_{10.8-12.1}$ entre le canal IR10.8 et le canal IR12.1 pour avoir des informations sur les différentes phases des nuages (figure 4.3(b)). Dans le cas de présence de glace : $\Delta T_{8.7-10.8}$ est plus grand que $\Delta T_{10.8-12.1}$.
- La différence de températures de brillance $\Delta T_{6.2-10.8}$ entre le canal WV6.2 et le canal IR10.8 correspond à l'altitude des nuages (haut, bas ou moyen).




Fig. 4.3. Probabilité de précipitation:(a) en fonction de $VIS_{0.6}$ et de $NIR_{1.6}$,
(b) en fonction de $\Delta T_{10.8-12.1}$ et $\Delta T_{8.7-10.8}$

➤ Paramètres spectraux durant la nuit

Pour identifier les nuages précipitants durant la nuit, nous avons utilisé les paramètres suivants :

- Les différences de températures de brillance : $\Delta T_{3.9-10.8}$, $\Delta T_{3.9-7.3}$, $\Delta T_{8.7-10.8}$, et $\Delta T_{10.8-12.1}$ pour l'information sur le paramètre CWP qui est une fonction du rayon effectif et de l'épaisseur optique des nuages (Voir figure 4.4 et figure 4.5). De plus, l'information sur la phase du nuage (eau ou glace) est donnée par : $\Delta T_{8.7-10.8}$ et $\Delta T_{10.8-12.1}$.
- La température de brillance $T_{10.8}$ du canal IR10.8 représente la température du sommet des nuages. Pour un nuage convectif la valeur de $T_{10.8}$ est plus basse que celle d'un nuage stratiforme.
- La différence de températures de brillance $\Delta T_{6.2-10.8}$ qui correspond à l'altitude des nuages (haut, bas ou moyen).

4.4.2 Paramètre temporel

Le paramètre temporel ($RCT_{10.8}$) est le taux de variation de la température de brillance $T_{10.8}$ du canal IR10.8 et qui correspond aux phases de développement du nuage [Vicente et al. 1998]. La valeur de ($RCT_{10.8}$) est donnée par l'équation suivante :

$$RCT_{10.8}(t) = \frac{T_{IR10.8}(t) - T_{IR10.8}(t-1)}{\Delta t} \quad (4.8)$$

Où Δt est l'intervalle de temps entre deux images (15mn pour MSG).




Fig. 4.4. LWP (Colonne gauche) et IWP (Colonne droite) en fonction de :
 (a) $\Delta T_{3.9-7.3}$ et $\Delta T_{3.9-10.8}$ (b) $\Delta T_{3.9-10.8}$ et $\Delta T_{8.7-10.8}$; (c) $\Delta T_{3.9-10.8}$ et $\Delta T_{10.8-12.1}$




Fig. 4.5. LWP (Colonne gauche) et IWP (Colonne droite) en fonction de :
 (a) $\Delta T_{3.9-7.3}$ et $\Delta T_{8.7-10.8}$; (b) $\Delta T_{3.9-7.3}$ et $\Delta T_{10.8-12.1}$; (c) $\Delta T_{8.7-10.8}$ et $\Delta T_{10.8-12.1}$

4.4.3 Paramètres de texture

Le paramètre de texture est déterminé à partir de la méthode des vecteurs de rangs [Ameur et al. 2006] présentée dans le chapitre précédent (paragraphe 3.4.4). Ainsi, pour chaque pixel $p(i,j)$ nous avons calculé la fréquence d'apparition des 24 rangs des niveaux de gris des pixels de la fenêtre 31x 31 pixels centrée en $p(i,j)$.

Chaque pixel est alors représenté par un vecteur de 24 composantes $(N_1, N_2, \dots, N_{24})$, où chaque valeur (N_i) est la fréquence d'apparition du vecteur de rang (i) .

4.4.4. Méthode d'identification et de classification des nuages précipitants

Pour l'identification des précipitations et la classification des nuages précipitants, nous avons développé deux réseaux de neurones MLP-D pour le jour et MLP-N pour la nuit. Chaque réseau est Constitué de 3 couches : une couche pour l'entrée, une couche cachée et une couche pour la sortie.

➤ **Les entrées de MLP-D sont :**


- Paramètres spectraux : $T_{IR10.8}$, $T_{IR10.8}-T_{IR12.1}$, $T_{IR8.7}-T_{IR10.8}$, $T_{WV6.2}-T_{IR10.8}$, $R_{VIS0.6}$, et $R_{NIR1.6}$).
- Paramètres de textures : $(N_1, N_2, \dots, N_{24})$.
- Paramètre temporel : $(RCT_{10.8})$.

➤ **Les entrées de MLP-N sont :**

- Paramètres spectraux : $T_{IR10.8}$, $T_{IR10.8}-T_{IR12.1}$, $T_{IR8.7}-T_{IR10.8}$, $T_{WV6.2}-T_{IR10.8}$, $T_{IR3.9}-T_{IR10.8}$, et $T_{IR3.9}-T_{WV7.3}$.
- Paramètres de textures : $(N_1, N_2, \dots, N_{24})$.
- Paramètre temporel : $(RCT_{10.8})$.

Par conséquent, les réseaux MLP-D et MLP-N contiennent chacun 31 neurones en entrée et 3 neurones pour la couche de sortie qui correspondent aux nuages convectifs, stratiformes et non-précipitants (figure 4.6).

Par ailleurs, pour déterminer le nombre de neurones de la couche cachée et les poids des connexions entre les neurones, nous avons effectué l'apprentissage des réseaux MLP-D et MLP-N avec une base de données constituée de 2109 scènes de précipitations collectées de novembre 2006 à Mars 2007 au nord de l'Algérie. Ainsi, le nombre de neurones de la couche cachée pour MLP-D et MLP-N qui minimise l'erreur quadratique moyenne RMSE (MLP-D=1,7% ; MLP-D=1,9%) après 800 itérations est de 35 neurones (figure 4.7). Aussi, le pas d'apprentissage et l'inertie correspondant aux deux réseaux sont respectivement $\eta=0,4$ et $\alpha= 0,6$. Aussi, nous avons réalisé l'apprentissage avec un ordinateur muni d'un processeur de 3,5 GHz et la durée d'apprentissage de chaque réseau est de 25 minutes.



$$X_7 = RCT_{10.8} ; (X_8, X_9 \dots X_{31}) = (N_1, N_2 \dots N_{24})$$

$$\text{MLP-D: Jour: } (X_1, X_2, X_3, X_4, X_5, X_6) = (T_{IR10.8}, T_{IR10.8}-T_{IR12.1}, T_{IR8.7}-T_{IR10.8}, T_{WV6.2}-T_{IR10.8}, R_{VIS0.6}, R_{NIR1.6})$$

$$\text{MLP-N: Nuit: } (X_1, X_2, X_3, X_4, X_5, X_6) = (T_{IR10.8}, T_{IR10.8}-T_{IR12.1}, T_{IR8.7}-T_{IR10.8}, T_{WV6.2}-T_{IR10.8}, T_{IR3.9}-T_{IR10.8}, T_{IR3.9}-T_{WV7.3})$$

Fig. 4.6. Structure des réseaux de neurones MLP-D et MLP-N




Fig. 4.7. Variation de l'erreur RMSE en fonction du nombre de neurones de la couche cachée et du nombre d'itérations d'apprentissage de MLP-D et MLP-N

4.4.5 Résultats et évaluation des performances

La base de données utilisée pour l'évaluation de notre technique est constituée d'images MSG et Radar prises durant la période de Novembre 2010 à Mars 2011 au nord de l'Algérie. Le nombre de scènes est de 14580. Pour évaluer notre technique les résultats obtenus sont comparées d'une part, avec les données radar, et d'autre part, avec les résultats obtenus par la méthode ECST utilisée dans la littérature scientifique comme référence.

Afin de valider notre approche nous avons calculé différents paramètres statistiques tels que: Probabilité de détection (POD); Probabilité de fausse détection (POFD), Ratio de Fausses Alarmes (FAR), Le biais (BIAS), Indice de réussite (CSI).

Ces paramètres sont calculés d'une part, à partir de la Table de contingence pour l'identification des nuages précipitants (table 4.4), et d'autre part, à partir de la table de contingence pour la classification des nuages précipitants en convectifs et stratiformes (table 4.5).

Par ailleurs, nous avons calculé les valeurs de S_Y respectivement R_Y à partir des équations (4-9) et (4-10)

$$S_Y = S_C + S_S \quad (4.9)$$

$$R_Y = R_C + R_S \quad (4.10)$$

Radar	Satellite		
	Précipitant	Non précipitant	Total
Précipitant	$S_Y R_Y$	$S_N R_Y$	R_Y
Non précipitant	$S_Y R_N$	$S_N R_N$	R_N
Total	S_Y	S_N	T_{SR}

Table 4.4. Table de contingence d'identification des nuages précipitants

Radar	Satellite		
	Convectif	Stratiforme	Total
Convectif	$S_C R_C$	$S_S R_C$	R_C
Stratiforme	$S_C R_S$	$S_S R_S$	R_S
Total	S_C	S_S	T_{SR}

Table 4.5. Table de contingence de classification des nuages précipitants en convectifs et stratiformes

A. Analyse statistique

Les paramètres $(Bias)_Y$, $(POD)_Y$, $(POFD)_Y$, $(FAR)_Y$, $(ETS)_Y$, $(CSI)_Y$ pour la détection des régions précipitantes sont donnés comme suit :

- Le Biais $(Bias)_Y$ décrit le rapport entre l'estimation par notre méthode et l'observation par Radar d'un événement précipitant. Il est donné par l'équation (4-11).

$$(Bias)_Y = \frac{S_Y R_Y + S_Y R_N}{S_Y R_Y + S_N R_Y} = \frac{S_Y}{R_Y} \in [0, \infty[, \text{optimal: } 1 \quad (4.11)$$

- La probabilité de détection $(POD)_Y$ est le rapport entre le nombre de pixels correctement identifiés comme précipitants par notre méthode, et le nombre de pixels précipitants observés par Radar. Elle est calculée par la relation suivante :

$$(POD)_Y = \frac{S_Y R_Y}{S_Y R_Y + S_N R_Y} = \frac{S_Y R_Y}{R_Y} \in [0,1], \text{ optimal: } 1 \quad (4.12)$$

- La probabilité de fausse détection $(POFD)_Y$ est le rapport entre le nombre de pixels incorrectement identifiés comme précipitant par notre méthode, et le nombre de pixels non précipitant observés par Radar. Elle est définie comme suit :

$$(POFD)_Y = \frac{S_Y R_N}{S_Y R_N + S_N R_N} = \frac{S_Y R_N}{R_N} \in [0,1], \text{ optimal: } 0 \quad (4.13)$$

:

- La fausse alarme $(FAR)_Y$ est le rapport entre Le nombre de pixels incorrectement identifié comme précipitants et le nombre total de pixels estimés comme précipitants par notre méthode. Elle calculée par la relation suivante :

$$(FAR)_Y = \frac{S_Y R_N}{S_Y R_Y + S_Y R_N} = \frac{S_Y R_N}{S_Y} \in [0,1], \text{ optimal: } 0 \quad (4.14)$$

- Indice de réussite cruciale $(CSI)_Y$ est le rapport entre le nombre de pixels correctement identifiés comme précipitants par notre approche , et la somme des pixels incorrectement identifiés comme précipitants avec le nombre de pixels précipitants observés par Radar. Il est défini comme suit :

$$(CSI)_Y = \frac{S_Y R_Y}{S_Y R_Y + S_N R_Y + S_Y R_N} = \frac{S_Y R_Y}{R_Y + S_Y R_N} \in [0,1], \text{ optimal: } 1 \quad (4.15)$$

Les paramètres $[(Bias)_C, (POD)_C, (POFD)_C, (FAR)_C, (ETS)_C, (CSI)_C]$ qui correspondent à la classification des nuages précipitants en convectifs et stratiformes sont calculés à partir des équations identiques à celles utilisées précédemment pour la détection des nuages précipitants. Il suffit alors de remplacer S_Y par S_C , R_Y par R_C , S_N par S_S et R_N par R_S .

B. Analyse des résultats

Nous avons calculé les paramètres statistiques pour les 1936 scènes précipitantes prises le jour et la nuit, et composées de 8022506 pixels précipitants dont 1824550 pixels ont été identifiés par Radar comme convectifs, et 6197956 pixels comme stratiformes. Les valeurs obtenues respectivement pour l'identification des nuages précipitants et leurs classification en convectifs et stratiformes sont données dans la table 4.6 et la table 4.7.

- **Identification des nuages précipitants**

L'analyse des valeurs des biais données dans la table 4.6 ($BIAS_Y$: 0,97 pour le jour et 0,95 pour la nuit) indique une légère sous estimation des nuages précipitants par notre approche(RACT-DN). En revanche, ces valeurs sont meilleures que celles obtenues par la technique ECST($BIAS_Y$: 0,83 pour le jour et 0,83 pour la nuit).

Par ailleurs, 82% et 78% des pixels précipitants observés par Radar respectivement pendant le jour et pendant la nuit ont été identifiés par notre technique (RACT-DN). En comparant ces valeurs avec celles obtenues par la technique ECST (POD_Y : Jour : 65% ; Nuit: 62%), nous constatons une meilleure performance de notre approche (RACT-DN) dans la détection des nuages précipitants pendant le jour et la nuit.

De plus, nous constatons une amélioration pendant le jour et la nuit des valeurs des paramètres $POFD_Y$ et FAR_Y obtenues par notre approche comparées à celles obtenues par la technique ECST. En effet, la valeur du $POFD_Y$ de notre approche (Jour: 1%; Nuit: 2%) montre une plus faible fraction d'événements non précipitants ont été classés comme précipitants comparé à la méthode ECST ($POFD_Y$: Jour : 6%; Nuit : 7%).

Aussi, la valeur du FAR indique une plus faible erreur d'estimation de pixels précipitants par notre approche (Jour: 17% ; Nuit: 21%) comparé à la méthode ECST (Jour: 29% ; Nuit : 31%).

Pour l'indice de réussite CSI_Y qui dépend des scènes précipitantes, on constate que la méthode RACT-DN avec un CSI_Y de (Jour: 0,74 ; Nuit: 0,72) est plus performante que la technique ECST (CSI_Y : Jour: 0,58 ; Nuit: 0,56).

Test	RACT-DN		ECST	
	Jour	Nuit	Jour	Nuit
$(BIAS)_Y$	0,97	0,95	0,83	0,83
$(POD)_Y$	0,82	0,78	0,65	0,62
$(POFD)_Y$	0,01	0,02	0,06	0,07
$(FAR)_Y$	0,17	0,21	0,29	0,31
$(CSI)_Y$	0,74	0,72	0,58	0,56

Table 4.6. Table de contingence d'identification des nuages précipitants, jour et nuit par les méthodes RACT-DN et ECST

- **Classification des nuages précipitants en convectifs et stratiformes**

L'analyse des valeurs de la table 4.7 montre que la méthode que nous avons développée (RACT-DN) est plus performante que la technique ECST dans la classification des nuages précipitants en convectifs et stratiformes pendant le jour et la nuit. En effet, la méthode (RACT-DN) affiche des valeurs de POD et CSI plus grandes et des valeurs de FAR et POFD plus petites que celles obtenues par la technique ECST.

En effet, 82% et 79% des pixels convectifs respectivement pendant le jour et la nuit ont été identifiés par notre approche. En outre, les valeurs de FAR indiquent que 29% et 30% des événements convectifs estimés par notre approche respectivement pendant le jour et la nuit ont été incorrectement classés. De plus, les valeurs de POFD montrent que 16% et 18% des événements stratiformes observés respectivement pendant le jour et la nuit ont été incorrectement classés comme convectifs par notre approche.

Par ailleurs, la technique ECST affiche d'une part, des valeurs de POD (Jour: 62% ; Nuit: 61%) inférieures à celles de RACT-DN, et d'autre part, des valeurs de FAR et POFD (Jour: FAR= 46%, POFD= 24% ; Nuit : FAR=46%, POFD=25%) supérieures à celles de RACT-DN.

La robustesse de notre approche par rapport à ECST dans la classification des nuages précipitants en convectifs et stratiformes pendant le jour et la nuit est confirmée par les valeurs de l'indice de réussite. En effet, pour RACT-DN les valeurs de CSI (Jour: 0,61 ; Nuit: 0,59) sont supérieures à celles de ECST (Jour: 0,53 ; Nuit: 0,53).

Test	RACT-DN		ECST	
	Jour	Nuit	Jour	Nuit
(BIAS) _C	1,10	1,12	0,83	0,83
(POD) _C	0,82	0,79	0,62	0,61
(POFD) _C	0,16	0,18	0,24	0,25
(FAR) _C	0,29	0,30	0,46	0,46
(CSI) _C	0,61	0,59	0,53	0,53

Table 4.7. Table de contingence de la classification des nuages précipitants en convectifs et stratiformes le jour et la nuit des méthodes RACT-DN et ECST.

Afin de visualiser les performances de notre méthode, nous présentons les résultats obtenus sur une image de la base de données prise le 06 janvier 2011(11:45 UTC). La figure 4.8 montre les résultats de l'identification des nuages précipitants : la figure 4.8(a) montre l'image de température de brillance du canal IR10.8, la figure 4.8(b) montre les régions détectées par Radar et par l'approche que nous avons développée (RACT-DN), et la figure 4.8(c) montre les zones identifiées par la technique ECST et par Radar. Les résultats de la classification des nuages précipitants en convectifs et stratiformes sont montrés dans la figure 4.9.

On constate que le nombre de pixels mal classés par ECST est plus important que celui de RACT-DN ce qui confirme les résultats statistiques obtenus précédemment.




Fig. 4.8 Identification et classification des nuages précipitants pour la scène du 06 Janvier 2011 (11:45 UTC). (a) BT10.8 image; (b) zones observées par Radar et identifiées par ECST ; (c) zones observées par Radar et identifiées par RACT-DN.




Fig. 4.9 Identification et classification des nuages précipitants (zones convectives et stratiformes) pour la scène du 06 Janvier 2011 (11:45 UTC). (a) BT10.8 image; (b) zones observées par Radar et identifiées par RACT-DN; (c) zones observées par Radar et identifiées par ECST.

CONCLUSION

La précision et l'efficacité des méthodes d'estimation des paramètres météorologiques par satellite tel que le taux de précipitation dépend des résultats de la technique choisie pour la détection et la discrimination des zones de précipitation. Dans cette optique, nous avons élaboré une méthode qui permet l'identification des régions précipitantes et la classification des nuages précipitants en deux classes principales convectifs et stratiformes. Notre approche est basée sur des caractéristiques spectrales, texturales et temporelles des nuages précipitants. Les paramètres utilisés dans notre approche correspondent à la structure microphysique et optique des nuages, à la phase (présence ou non de glace aux sommets des nuages), à la texture, et au taux de variation de la température infrarouge des nuages entre deux images consécutives.

Nous avons appliqué deux réseaux de neurones multicouches (MLP-D et MLP-N) pour la classification de la zone d'étude en trois classes : nuages convectifs, nuages stratiformes, et régions non précipitantes, MLP-D pour le jour et MLP-N pour la nuit. L'apprentissage et la validation des deux réseaux de neurones ont été réalisés en utilisant une base de données constituée d'images prises par le satellite MSG et par le radar météorologique situé dans la région de Sétif au nord de l'Algérie.

Les résultats obtenus par notre méthode ont été comparés avec les données radar et avec les résultats de la méthode de référence ECST (Enhanced Convective Stratiform Technique) qui est basée uniquement sur l'infrarouge. L'analyse des résultats nous a permis de vérifier les performances de notre approche et de constater sa robustesse par rapport à la méthode ECST, d'une part, dans l'identification des précipitations, et d'autre part, dans la classification des nuages précipitants en convectifs et stratiformes.

De plus, un autre avantage de notre approche est son application pendant le jour et la nuit. En perspective, notre méthode peut être améliorée en ajoutant d'autres types de données comme les micro-ondes et radar issues de capteurs embarqués dans des satellites comme le TRMM (Tropical Rainfall Measuring Mission).

Bibliographie

Adler, R. F., Negri, A. J., 1988. "A satellite infrared technique to estimate tropical convective and stratiform rainfall". *Journal of Applied Meteorology*, 27, 30–51.

Akono, A., Tonyé, E. et Rudant, J.P., 2003. "Classification texturale d'une image radar à synthèse d'ouverture dans une région volcanique : le cas de la région du mont Cameroun". *Télédétection* ; vol. 3 , n° 2-3-4, pp.111-124.

Ameur, Z., Adane, A., Ameur, S. , 2006. "Determination of the Grey Level Ranks for the Segmentation of Textured Images". *IEEE ISIE 2006, July 9-12, 2006, Montreal, Quebec, Canada*, pp. 435-440.

Ameur, Z., Ameur, S., Adane, A., Sauvageot, H., Bara, K., 2004. "Cloud classification using the textural features of Meteosat images". *Int J Remote Sens.* Vol.25, pp. 4491–4503.

Ameur, S., Bara, K., Adane, A., Zerhouni, N., 2001. "Effect of the texture anisotropy in the classification of remote sensing images", *Systems Analysis-Modelling Simulation-SAMS*,2001, Vol.40, pp. 309-327.

Anagnostou, E.N., Kummerow, C. "Stratiform and convective classification of rainfall using SSM/I 85-GHz brightness temperature observations". *J Atmos Ocean Techn* 14:570–575, 1997.

Arkin, P.A., Meisner, B.N., 1987. "The relationship between large-scale convective rainfall and cold cloud over the western hemisphere during 1982–84". *Mon Wea Rev* 115:51–74.

Arking, A., Childs, J.D. , 1985. "Retrieval of cloud cover parameters from multispectral satellite images". *J. Appl. Meteor.* 24:322–333.

Arthur, D., Vassilvitskii, S., 2007. "k-means++ : the advantages of careful seeding". Dans *Proc. of ACM-SIAM Symposium On Discrete Algorithms*, Nouvelle Orléans, Louisiane, États-Unis, pages 1027–1035, Philadelphie, Pennsylvanie, État-Unis. Society for Industrial and Applied Mathematics.

Ba, M. B. et Gruber, A., 2001. "GOES Multispectral Rainfall Algorithm (GMSRA)". *J. Appl. Meteorol.*, 40, 1500–1514. doi:10.1175/1520-0450(2001).

Baillie, J., 2005. Cours de segmentation (e322).

Ball, G., Hall, D., 1965. "ISODATA: A novel method of data analysis and pattern classification", In Technical report, Stanford Research Institute, Menlo Park, USA.

Bandyopadhyay, S., 2005. "Satellite image classification using genetically guided fuzzy clustering with spatial information". *International Journal of Remote Sensing*, 26(3) :579–593.

Barba, D., Ronsin, J. et Raboisson, S., 1985. "Segmentation d'images par intégrales curvilignes", 10ème colloque sur le traitement du signal et ses applications , pp.723-728.

- Beil, F.M., 1999. "Approche structurale de l'analyse de la texture dans les images cellulaires 2D et 3D" ; Thèse de l'Université Paris 7.
- Bellerby, T., Todd, M., Kniveton, D., Kidd, C., 2000. "Rainfall estimation from a combination of TRMM precipitation radar and GOES multispectral satellite imagery through the use of an artificial neural network," *J. Appl. Meteorol.*, vol. 39, pp 2115-2128.
- Bendix, J., 2000. "Precipitation dynamics in Ecuador and Northern Peru during the 1991/92 El Nino: a remote sensing perspective". *International Journal of Remote Sensing*, 21: 533-548.
- Bendix, J., 1997. "Adjustment of the Convective-Stratiform Technique (CST) to estimate 1991/93 El Nino rainfall distribution in Ecuador and Peru by means of Meteosat-3 IR data". *International Journal of Remote Sensing*, 18: 1387-1394.
- Bergeron, T., 1968. Studies of the orogenic effect on the areal fine structure of rainfall distribution. Rep. 6, Meteorological Institute, Uppsala University, Uppsala, Sweden, 42 pp.
- Besag, J., 1986. "On the Statistical Analysis of Dirty Pictures", *Journal of the Royal Statistical Society*, vol. B-48, pp. 259-302.
- Bezdek, J., 1981. Pattern recognition with fuzzy objective functions. Plenum Press, New York.
- du Buf, J.M.H., 1989. "Towards unsupervised texture segmentation using Gabor spectral decomposition", 5th Int. Conf. on Image Analysis and Processing ; Positano (Italy), pp. 65-72 .
- Caloz, R., Collet, C., 2001. "Précis de télédétection : traitements numériques d'images de télédétection", vol. 3, 386p.
- Camps-Valls, G., Gomez-Chova, L., Calpe, J., Soria, E., Martin, J., Alonso, L., Moreno, J., 2006a. "Robust vector support method for hyperspectral data classification and knowledge discovery". *IEEE Transactions on Geoscience and Remote sensing*, 42(8) :1530–1542.
- Camps-Valls, G., Gomez-Chova, L., Munoz-Mari, J., Vila-Frances, J., Calpe-Maravilla, J., 2006b. "Composite kernels for hyperspectral image classification". *Geoscience and Remote Sensing Letters*, 3(1) :93–97.
- Cheng, H.D., Sun, Y., 2000. "A hierarchical approach to color image segmentation using homogeneity", *IEEE Transactions on Image Processing*, vol. 9, Issue 12, pp. 2071–2082.
- Chuang, K., Tzeng, H., Chen, S., Wu, J., Chen, T., 2006. "Fuzzy c-means clustering with spatial information for image segmentation". *Computerized Medical Imaging and Graphics*, 30(1) :9–15.
- Collier, C. G., 1989. Applications of Weather Radar Systems. A Guide to Uses of Radar Data in Meteorology and Hydrology. Halsted Press: A division of John Wiley & Sons, New York NY, USA, 294 pp.
- Coquerez, J., 1995. Analyse D'images - Filtrage Et Segmentation. Masson.

Cornet, C., 2003. Restitution de paramètres nuageux par méthodes neuronales dans des cas de nuages hétérogènes à couverture fractionnaire, Thèse de Doctorat, Université Blaise Pascal.

Coulier, P. J., 1875. "Note sur une nouvelle propriété de l'air", *J. de Pharmacie et de Chimie, Paris, Ser. 4*, 22:165 -173.

Del Frate, F., Ortenzi, A., Casadio, S., Zehner, C., 2002. "Application of neural algorithms for a realtime estimation of ozone profiles from GOME measurements", *IEEE T. Geosci. Remote*, 40, 2263–2270.

Delrieu, G., Andrieu, H., Creutin, J. D., 2000 . "Quantification of Path-Integrated Attenuation for X- and C-Band Weather Radar Systems Operating in Mediterranean Heavy Rainfall". *J. Appl. Meteorol.*, 39, 840–850.

Delrieu, G., Creutin, J.D., Saint-Andre, I., 1991. "Mean K-R Relationships: Practical Results for Typical Weather Radar Wavelengths". *J. Atmos. Oceanic Technol.*, 8, 467–476.

Deriche, R., 1987. "Using Canny's criteria to derive a recursively implemented optimal edge detector", *Int. Journal of Computer Vision*, vol.1, n°2, pp.167-187.

D'hondt, O., 2006. "Analyse spatiale de texture non stationnaire dans les images SAR", Thèse de l'Université de Rennes I.

Doviak, R. J., Zrnic, D.S., 1993. *Doppler radar and weather observations*. 2nd ed., Academic Press, San Diego CA, USA, 562 pp.

Ebert, E. E., Janowiak, J. E., Kidd, C., 2007. "Comparison of near-real-time precipitation estimates from satellite observations and numerical models". *Bulletin of the American Meteorological Society*, 88(1), 47–64. <http://dx.doi.org/10.1175/BAMS-88-1-47>.

Efros, A.A., Freeman, W.T., 2001. "Image Quilting for Texture Synthesis and Transfer", *Proceedings of SIGGRAPH '01* ; Los Angeles ; California.

EUMETSAT(2004). "Applications of Meteosat Second Generation - Conversion from Counts to Radiances and from Radiances to Brightness Temperatures and Reflectance", http://oiswww.eumetsat.org/WEBOPS/msg_interpretation/index.html

Faure, T., H. Isaka, B. Guillemet., 2001a. "Neural network analysis of the radiative interaction between neighboring pixels in inhomogeneous clouds", *J. Geophys. Res.*, 106, 14465-14484.

Faure, T., H. Isaka, B. Guillemet., 2001b. "Mapping neural network computation of high resolution radiant fluxes of inhomogeneous clouds", *J. Geophys. Res.*, 106, 14961-14974.

Fauvel, M., 2007. Spectral and Spatial Methods for the Classification of Urban Remote Sensing Data. PhD thesis, Grenoble Institute of Technology and Faculty of Engineering, University of Iceland.

Fauvel, M., Chanussot, J., Benediktsson, J., 2007 . "Classification en imagerie hyperspectrale haute résolution : utilisation conjointe de l'information spatiale et spectrale" . In *Colloque GRETSI*, pages 737–740. Troyes, France.

Feidas, H., Giannakos, A., 2011. "Classifying convective and stratiform rain using multispectral infrared Meteosat Second Generation satellite data". *Theor. Appl. Climatol.* DOI 10.1007/s00704-011-0557-y.

Feidas, H., Giannakos, A., 2012. "Classifying convective and stratiform rain using multispectral infrared Meteosat Second Generation satellite data". *Theor Appl Climatol.* 108(3): 613–630.

Fortier, M.F.A., Ziou, D., Armenakis, C., Xang, S., 1999. "Nouvelles perspectives en détection de contours: textures et images multispectrales", *vision interface*, trios rivière, pp.19-21.

Früh, B., Bendix, J., Nauss, T., Paulat, M., Pfeiffer, A., Schipper, J.W., 2007. "Verification of precipitation from regional climate simulations and remote-sensing observations with respect to ground-based observations" in the upper Danube catchment. *Meteorologische Zeitschrift*, 16(3), 275–293. <http://dx.doi.org/10.1127/0941-2948/2007/0210>.

Galloway, M.M., 1975. "Texture analysis using gray level run lengths", *Computer Graphics Image Processing*, vol. 4, pp. 172-179.

Garrigues, S., 2004. "Hétérogénéité Spatiale des surfaces Terrestres en Télédétection: Caractérisation et Influence sur l'estimation des variables biophysiques". Thèse de l'Ecole Nationale Supérieure Agronomique de Rennes, pp. 362.

GDTA(1991).Note de cours:http://ceos.cnes.fr:8100/cdrom-00/ceos1/science/baphygb/conclu_f.htm

Geman, S., Geman, D., 1984. "Stochastic Relaxation, Gibbs Distribution, and the Bayesian Restoration of Images", *IEEE Transactions on Pattern Analysis and Machine Intelligence*, vol. PAMI-6, no. 6, pp. 721-741.

Giannakos, A., Feidas, H., 2013. "Classification of convective and stratiform rain based on the spectral and textural features of Meteosat Second Generation infrared data". *Theor Appl Climatol.* Vol. 113, pp. 495–510.

Girard, C.M., Girard, M.C., 1999. *Traitement des données de télédétection*. Edition DUNOD Paris, ISBN 2 10 004185 1, pp. 527.

Glickman, T.S., 2000. "*Glossary of meteorology*". Am. Meteor. Soc., Boston.

Gong, Y., Shu, N., 2007. "Texture segmentation of multispectral remote sensing image based on markov random field". *Geomatics and Information Science of Wuhan University*, 32(3) :212–215.

Gu, Z.Q., Duncan, C.N., Grant, P.M., Cowan, C.F.N., Renshaw, E., Muggleston, M.A., 1991. "Textural and spectral features as an aid to cloud classification", *International Journal of Remote Sensing*, vol. 12, n° 5, pp. 953-968.

Gualtieri, J., Chettri, S., 2000. "Support vector machines for classification of hyperspectral data". In *Geoscience and Remote Sensing Symposium (IGARSS)*, volume 2, pages 813–815, Honolulu, HI.

Gunn, K. L. S., East, T. W. R., 1954. The microwave properties of precipitation particles. *Q. J. R. Meteorol. Soc.*, 80, 522–545.

- Haralick, R.M., 1979. "Statistical and structural approaches to texture", Proceedings IEEE , vol. 67, n° 5 , pp. 786-803.
- Haykin, S., 1994. "Neural networks: A comprehension foundation". Maxwell Macmillan, Canada.
- Hazel, G., 2000. "Multivariate gaussian mrf for multispectral scene segmentation and anomaly detection". IEEE Transactions on Geoscience and Remote Sensing (GRS), 38(3) :1199–1211.
- Hong, Y., Kummerow, C.D., Olson, W.S., 1999. "Separation of convective and stratiform precipitation using microwave brightness temperature". J Appl Meteor 38:1195–1213.
- Hornik, K., Stinchcombe, M. B., White, H., 1989. "Multilayer feedforward networks are universal approximators". Neural Networks, 2(5):359–366.
- Houghton, H.G., 1968. "On precipitation mechanisms and their artificial modification". *J. Appl. Meteor.*, 7, 851-859.
- Houze, R., 1997. "Stratiform precipitation in regions of convection: a meteorological paradox?" *Bull.Amer. Meteor. Soc.*, 78, 2179-2196.
- Houze, R., 1993. *Cloud dynamics*. International Geophysics Series, **53**, Academic Press, 573 pp.
- Huang, C., Davis, L., Townshend, J., 2002. "An assessment of support vector machine for land cover classification". International Journal of Remote Sensing, 23(4) :725-749.
- Huang, T. Z., Huang, X. Q., Jiang, Z. Y., 2008. "Hyperspectral image labeling using mrf and gm models". Dianzi Keji Daxue Xuebao/Journal of the University of Electronic Science and Technology of China, 37(5).
- Huang, Z., Turner, B., Dury, S., Wallis, I., Foley, W., 2004. "Estimating foliage nitrogen concentration from himap data using continuum removal analysis". Remote Sensing of Environment, 93(1-2) :18–29.
- Ikonomakis, N., Pataniotis, K.N., Venetsanopoulos, A.N., 2000. "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.
- Inoue, T., 1987b. "An instantaneous delineation of convective rainfall areas using split window data of NOAA-7 AVHRR". *J. Meteorol. Soc. Japan*. Vol. 65, pp. 469–481.
- Jain, S., Bhatia, M.P.S., 2013. "Performance Investigation of Support Vector Regression using Meteorological Data" , International Journal of Database Theory and Application Vol. 6, No. 4, pp.109-117.
- Jones, D., 1956. *Rainfall drop-size distribution and radar reflectivity*. Illinois State Water Survey.
- Karimi, Y., Prasher, S. O., Patel, R. M., Kim, S. H., 2006. "Application of support vector machine technology for weed and nitrogen stress detection in corn". Computers and Electronics in Agriculture, 51(1-2) :99–109.

Kaur, R., Ganju, A., 2008. "Cloud classification in NOAA AVHRR imageries using spectral and textural features". *J Indian Soc Remote Sens.* Vol. 36, pp. 167–174.

Kayitakire, F., Giot, P., Defourny, P., 2002. "Discrimination automatique de peuplements forestiers à partir d'orthophotos numériques couleur : un cas d'étude en Belgique", *Journal canadien de télédétection*, vol. 28 ; n° 5, pp. 629-640.

Kirkpatrick, S., Gellatt, C. D., Vecchi, M. P., 1982. "Optimization by simulated annealing", IBM Thomas J. Watson research Center, Yorktown Heights, New York.

Kpalma, K., 1992. "Analyse fractale de textures naturelles dans un contexte multiresolution : Application à la segmentation d'images multirésolution" ; Thèse de l'INSA de Rennes.

Kramer, A.H., Sangiovanni-Vincentelli, A., 1989. "Efficient parallel learning algorithms for neural networks". In *advances in Neural Information Processing Systems 1* (D.S. Touretzky, ed.), San Mateo, CA: Morgan Kaufmann, pp. 40-48.

Kühnlein, M., Thies, B., Nauss, T., Bendix, J., 2010. " Rainfall rate assignment using MSG SEVIRI data – a promising approach to spaceborne rainfall rate retrieval for midlatitudes". *Journal of Applied Meteorology and Climatology*, 49(7), 1477–1495. <http://dx.doi.org/10.1175/2010JAMC2284.1>.

Lamarck, J.B., 1802. "Sur la forme des nuages". *Annuaire météorologique n° 3 pour l'an X*, pp. 149-164.

Laviola, S., Levizzani, V., 2011. "The 183-WSL fast rain rate retrieval algorithm". Part I. Retrieval design. *Atmos Res* 99(3-4):443–461.

Lazri, M., Ameer, Z., Ameer, S., Mohia, Y., Brucker, J.M., Testud, J., 2013. "Rainfall estimation over a Mediterranean region using a method based on various spectral parameters of SEVIRI MSG". *J. Adv. Space Res* . <http://dx.doi.org/10.1016/j.asr.2013.07.036>.

Lee, J., Weger, R. C., Sengupta, S. K., Welch, R.M., 1990. "A neural network approach to cloud classification". *IEEE Transactions on Geoscience and Remote Sensing*, 28, 846-855.

Lee, Y., Wahba, G., Ackerman, S., 2004. "Classification of Satellite Radiance Data by Multicategory Support Vector Machines," *Journal of Atmospheric and Oceanic Technology*, 21, 159–169.

Lefsky, M.A., Cohen, W.B., 2003. "Selection of remotely sensed data". *Remote Sensing of Forest Environments: Concepts and Case Studies*, pp.13-44.

Lensky, I.M., Rosenfeld, D., 2003a. "A night-rain delineation algorithm for infrared satellite data based on microphysical considerations". *J. Appl. Meteorol.* 42:1218–1226.

Levizzani, V., Mugnai, A., 2004. "Rainfall measurements from space: Where are we ?", *Proceedings of the 14th International Conference on Clouds and Precipitation*, Bologna, Italy, 1123-1126.

- Levizzani, V., 2003. "Satellite rainfall estimates: New perspectives for meteorology and climate from the EURAINSAT project". *Annals of Geophysics*, 46, 363–372.
- Levizzani, V., Schmetz, J., Lutz, H. J., Kerkmann, J., Alberoni, P. P., Cervino, M., 2001. "Precipitation estimations from geostationary orbit and prospects for Meteosat Second Generation". *Meteorological Applications*, 8(1), 23–42. <http://dx.doi.org/10.1017/S1350482701001037>.
- Li, P., Xiao, X., 2007. "Multispectral image segmentation by a multichannel watershed-bases approach". *International Journal of Remote Sensing*, 28(19) :4429–4452.
- Li, J., P. Menzel, Z. Yang, R. A. Frey, S. Ackerman., 2003. "High-spatial-resolution surface and cloud-type classification from MODIS multispectral band measurements", *J. Appl. Meteorol.*, 42, 204-226.
- Li, S., 1995. *Markov Random Field Modeling in Computer Vision*. Springer-Verlag.
- Mallat, S.G., 1989. "A theory for multiresolution signal decomposition: the wavelet representation". *IEEE Trans. on Pattern Anal. And Machine Intelligence*. Vol. PAM-11 ; N° 7.
- Martinez-Uso, A., Plat, F., Garcia-sevilla, P., 2005. "Multispectral image segmentation by energy minimization for fruit quality estimation", *pattern recognition and image analysis*, volume 3523, pp. 689-696.
- Matsuyama, T., Miura, S., Nagao, M., 1983. "Strural analysis of natural textures by Fourier transformation". *Compt. Vis. Graph. Image Processing*, vol. 25, pp. 347-362.
- McDonald, S., Niemann, K., Goodenough, D., Dyk, A., West, C., Tian Han Murdoch, M., 2003. "Hyperspectral remote sensing of conifer chemistry and moisture". In *IEEE International Geoscience and Remote Sensing Symposium (IGARSS)*, Toulouse, France, volume 1, pp. 552–554.
- Marshall, J. S., Hitschfeld, W., Gunn, K. L. S., 1955. "Advances in Radar Weather". *Adv. Geophys.*, 2, 1–56.
- Mather, P.M., So, B.T., Koch, M., 1998. "An evaluation of Landsat TM spectral data and SAR-derived textural information for lithological discrimination in the red sea Hills, Sudan" ; *International Journal of Remote Sensing*. Vol. 19 , n° 4, pp.587-604.
- Melgani, F., Bruzzone, L., 2004. "Classification of hyperspectral remote sensing images with support vector machine". *IEEE Transactions on geoscience and remote sensing*, 42(8) :1778–1790.
- Mercier, G., Derrode, S., Lennon, M., 2003. "Hyperspectral image segmentation with markov chain model". In *IEEE, editor, Geoscience and Remote Sensing Symposium (IGARSS)*, volume 6, pages 3766– 3768, Toulouse, France.
- Mie, G., 1908. "Beitrage zur Optik truber Medien, speziell kolloidaler Metallosungen". *Annalen der Physik*, 330, 377–445.

Minsky, Marvin., Papert, Seymour. Perceptrons, MIT Press, 1969 (Enlarged edition, 1988). “A seminal work that developed the modern theory of computational geometry and established fundamental limitations of loop-free connectionist learning machines”.

Mitchell, O.R., Myers, C.R., Boyne, W., 1977. “A max-min measure for image texture analysis”. IEEE Trans. On Comput. pp. 409-414.

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

Müller, M. D., Kaifel, A. K., Weber, M., Tellmann, S., Burrows, J. P., Loyola, D., 2003. “Ozone profile retrieval from Global Ozone Monitoring Experiment (GOME) data using a neural network approach (Neural Network Ozone Retrieval System (NNORSY))” ; Journal of geophysical research, Vol. 108, No. D16, 4497, doi:10.1029/2002JD002784.

Myint, S.W., 2003. “Fractal approaches in texture analysis and classification of remotely sensed data: Comparisons with spatial autocorrelation techniques and simple descriptive statistics”; International Journal of Remote Sensing ; 24 ; 1925-1947.

Nauss, T., Kokhanovsky, A. A., 2006. “Discriminating raining from non-raining clouds at mid-latitudes using multispectral satellite data”. Atmospheric Chemistry and Physics, 6(1), 5031–5036. <http://dx.doi.org/10.5194/acpd-6-1385-2006>.

Nauss, T., Kokhanovsky, A. A., 2007. “Assignment of rainfall confidence values using multispectral satellite data at mid-latitudes: First results”, Adv. Geosci., 10, 99– 102.

Nauss, T., Thies, B., Bendix, J., 2007. “Detection of high Rain Clouds using Water Vapour Emission - Transition from Meteosat First (MVIRI) to Second Generation (SEVIRI)”, *Geophysical Research*, Vol. 9, 05252.

Nuzillard, D., Lazar, C., 2007. “Partitionnal Clustering Techniques for multispectral image segmentation”, Journal of Computers, vol. 2, n° 10, pp.1-8.

Olthof, I., Fraser, R.H., 2007. “Mapping northern land cover fractions using Landsat ETM+”. *Remote Sensing of Environment*, 107, pp. 496-509.

Ouattara, S., 2009. “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.

Ouma, Y.O., Tateishi, R., 2005. “A fast environmental change detection approach based on unsupervised multiscale texture clustering” . International Journal of Environmental Studies, 62(1), pp.79-93.

Peleg, S., Werman, M., Rom, H., 1987. “A unified approach to the change of resolution: space and grey level” ; Proceeding of the Scandinavian Conference on Image Analysis ; Stockholm (Sweden). Vol. 1, pp.359-366.

Reudenbach, C., Heinemann, G., Heuel, E., Bendix, J., Winiger, M., 2001. "Investigation of summertime convective rainfall in Western Europe based on a synergy of remote sensing data and numerical models". *Meteorol. Atmos. Phys.* Vol. 76, pp. 23–41.

Roebeling, R. A., Holleman, I., 2009. "SEVIRI rainfall retrieval and validation using weather radar observations". *Journal of Geophysical Research*, 114(D21), 1–13. <http://dx.doi.org/10.1029/2009JD012102>.

Roli, F., Fumera, G., 2001. Support vector machine for remote-sensing image classification. In SPIE, editor, *Image and Signal Processing for Remote Sensing VI*, volume 4170, pages 160–166.

Rosenblatt, F., 1958. "The perceptron: a probabilistic model for information storage and organization in the brain". *Psychol. Rev.* 65, 386–408.

Rosenfeld, D., Lensky, I. M., 1998. "Satellite-based insights into precipitation formation processes in continental and maritime convective clouds". *Bulletin of the American Meteorological Society*, 79, 2457–2476. [http://dx.doi.org/10.1175/1520-0450\(2003\)](http://dx.doi.org/10.1175/1520-0450(2003)).

Rosenfeld, D., Gutman, G., 1994. "Retrieving microphysical properties near the tops of potential rain clouds by multispectral analysis of AVHRR data". *Atmospheric Research*, 34, 259–283.

Roula, M.A., Bouridane, A., Kurugollo, F., Amira, A., 2002. "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.

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

Rui Y., Huang T.S., Chang S., 1999. "Image retrieval: current techniques, promising directions, and open issues" ; *Journal of Visual Communications and Image Representation*, vol.10, pp. 39-62.

Satyanarayana, P., Srinivas, V.V., 2011. "Regionalization of precipitation in data sparse areas using large scale atmospheric variables – A fuzzy clustering approach", *Journal of Hydrology*, 405 : 462–473.

Sauvageot, H., Despau, G., 1990. "SANAGA, un système d'acquisition numérique et de visualisation des données radar pour la validité des estimations satellitaires des précipitations". *Veille Climatique Satellitaire*, n°31. pp. 51-55.

Sauvageot, H., 1982. *Radarmétéorologie : télédétection active de l'atmosphère*. Editions Eyrolles, Paris, France, 296 pp.

Sehad, M., Lazri, M., Ameer, S., Brucker, J.M., Ouallouche, F., 2014a. "Image Segmentation Method for Identifying Convective and Stratiform Rain using MSG SEVIRI Data", *International Journal of Image, Graphics and Signal Processing(IJIGSP)*, Vol. 6, N° 7, pp. 28-35.

Sehad, M., Ameer, S., Brucker, J.M., Lazri, M., 2014b. "MSG SEVIRI Image Segmentation Using a Method Based on Spectral, Temporal and Textural Features", *International Review on Computers and Software (IRECOS)*, Vol 9, N°4, pp. 618-627.

Sekhon, R., Srivastava, R., 1970. "New size spectra and radar reflectivity". *J. Atmos. Sci.*, 27, 299–307,

Simonneaux, V., Duchemin, B., Helson, D., Er-Raki, S., Oliso, A., Chehbouni, A.G., 2008. "The use of high-resolution image time series for crop classification and evapotranspiration estimate over an irrigated area in central Morocco". *International Journal of Remote Sensing*, 29, pp. 95-116.

Simpson, J., Adler, R.F., North, G., 1998. "A proposed Tropical Rainfall Measurement Mission (TRMM) satellite". *Bull Am Meteorol Soc* 69:278–295.

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

Thies, B., Turek, A., Nauss, T., Bendix, B., 2010. "Weather type dependent quality assessment of a satellite-based rainfall detection scheme for the mid-latitudes". *Meteorol. Atmos. Phys.* 107: 81–89. DOI 10.1007/s00703-010-0076-x.

Thies, B., Nauss, T., Bendix, J., 2008a. "Discriminating raining from non-raining clouds at mid-latitudes using meteosat second generation daytime data". *Atmos. Chem. Phys.*, 8, 2341–2349.

Thies, B., Nauss, T., Bendix, J., 2008b. "Delineation of raining from non raining clouds during nighttime using Meteosat-8 data". *Meteorol Appl* 15:219–230.

Thies, B., Nauss, T., Bendix, J., 2008c. "Precipitation process and rainfall intensity differentiation using Meteosat Second Generation SEVIRI data". *Journal of Geophysical Research*, 113, D23206, <http://dx.doi.org/10.1029/2008JD010464>.

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

Trias Sanz, R., 2006. "Classification semi-automatique du terrain en zone rurale par télédétection à haute résolution". Thèse de doctorat de l'Université Paris 5.

Tsai, D.M., Lin, C.P., Huang, K.T., 2005. "Defect detection in coloured texture surfaces using Gabor filters" ; *Imaging Science Journal* ; 53(1) , pp. 27-37.

Uddstrom, M.J., Gray, W., 1996. "Satellite cloud classification and rain rate estimation using multispectral radiances and measures of spatial texture". *J Appl Meteor.* Vol. 35, pp. 839–858.

Vapnik, V., 1998. *Statistical Learning Theory*. Wiley, New York.

Vicente, G.A., Davenport, J.C., Scofield, R.A., 2002. "The role of orographic and parallax corrections on real time high resolution satellite rainfall rate distribution". *Int. J. Rem. Sens.* Vol. 23(2), pp.221–230.

Vicente, G.A., Scofield, R.S., Menzel, W.P., 1998. "The operational GOES infrared rainfall estimation technique". *Bull. Amer. Meteorol. Soc.* Vol. 79, pp. 1883–1898.

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

Wang, H., Fei, B., 2008. A modified fuzzy c-means classification method using multiscale diffusion filtering scheme. *Medical image analysis*.

Wechsler, H., Kidode, M., 1979. "A random walk procedure for texture discrimination". *Pattern Analysis and Machine Intelligence, IEEE*. Vol: PAMI-1, n° 3, pp. 272-280.

Xue, H., Géraud, T., Duret-Lutz, A., 2003. "Multi-band segmentation using morphological clustering and fusion- application to color image segmentation", *IEEE international conference on image processing*.

Yuter, S., Houze, R.A., 1995. "Three-dimensional kinematic and microphysical evolution of Florida cumulonimbus. Part III: Vertical mass transport, mass divergence, and synthesis". *Mon. Wea. Rev.*, 123, 1964-1983.

Zahraie, B., Roozbahani, A., 2011. "SST clustering for winter precipitation prediction in southeast of Iran: Comparison between modified K-means and genetic algorithm-based clustering methods", *Expert Systems with Applications*, 38, 5919–5929.

Zucker, S., 1976. "Region growing: Childhood and adolescence" ; *Computer Vision, Graphics and Image Processing*, 5, 382-399.