

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

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



Thèse de doctorat

Spécialité : Electronique

Présentée par : M.MOHIA Yacine

Titre :

**Analyse et classification d'images multispectrales basée sur
l'extraction des paramètres texturaux et spectraux des images MSG**

Le 25 février 2018 devant le jury d'examen composé de :

Mr ADANE Abd-El-Hamid	Professeur à l'USTHB	Président
Mr AMEUR Soltane	Professeur à l'UMMTO	Rapporteur
Mr HADDAD Boualem	Professeur à l'USTHB	Examineur
Mr BOUTARFA Abdelhalim	Professeur à l'Université de Batna	Examineur
Mme AMEUR Zohra	Professeur à l'UMMTO	Examineur
Mr LAHDIR Mourad	Maitre de conférence A à l'UMMTO	Examineur

REMERCIEMENTS

Le travail que nous avons l'honneur de présenter, a été effectué en grande partie au niveau du laboratoire d'Analyse et de Modélisation des Phénomènes Aléatoires (LAMPa) de la Faculté de Génie Electrique et d'Informatique de l'UMMTO.

J'exprime mes sincères remerciements à mon directeur de thèse, le Professeur Soltane AMEUR, pour m'avoir guidé et encouragé tout au long de l'accomplissement de ce travail. Son aide précieuse à travers ses connaissances, ses conseils et ses encouragements, m'a été d'un grand secours. Qu'il soit assuré de ma profonde reconnaissance.

Je suis heureux que le professeur Abd-El-Hamid ADANE, ait accepté de présider ce jury. Cela est un grand honneur pour moi, d'autant plus qu'il m'a fait profiter de sa grande expérience lors des discussions que j'avais l'honneur d'avoir avec lui. Qu'il trouve ici, le témoignage de ma gratitude.

Que Monsieur Boualem HADDAD, Professeur à l'USTHB, trouve ici l'expression de mes remerciements les plus respectueux pour sa gentillesse et l'intérêt qu'il a porté à ce travail en acceptant de participer à ce jury.

A Monsieur Abdelhalim BOUTARFA, Professeur à l'Université de Batna, j'exprime ma plus grande reconnaissance pour son soutien permanent, ses précieux conseils et ses encouragements. C'est avec un énorme plaisir que je le vois prendre part à ce jury.

Ma profonde reconnaissance va à Madame Zohra AMEUR, Directrice du laboratoire LAMPa en acceptant de faire partie du jury et sa grande disponibilité et pour tous les conseils qu'elle m'a apportés tout au long de ce travail au cours de ces années.

Je remercie vivement Monsieur Mourad LAHDIR, Maître de conférences à l'UMMTO, pour avoir accepté de faire partie du jury. Je lui exprime ici toute ma gratitude pour toutes ses remarques pertinentes qu'il m'a formulées et qui m'ont été d'un apport précieux.

Je tiens à remercier mes collègues du laboratoire et plus particulièrement monsieur LAGHROUCHE Mourad pour ses précieux conseils et encouragements, ainsi que mes collègues que j'ai côtoyé au sein des différentes facultés.

Mes vifs remerciements vont également à Monsieur Jean Michel BRUCKER Directeur Scientifique de l'EPMI de CERGY pontoise, à Monsieur Karim LABADI et Monsieur Samir HAMACI. Je leur exprime ma plus grande reconnaissance de m'avoir bien accueilli et beaucoup aidé durant mes différents séjours scientifiques au niveau de l'école.

Avant de terminer ces remerciements, je voudrais évoquer tous les membres de ma famille, DAomar MOHAMED YAHIAOUI et ma bien aimée Naziha qui ont toujours été là pour me soutenir. Je ne trouverai pas de mots assez forts pour leur exprimer ma reconnaissance pour leur confiance et leur soutien moral ayant contribué pour une grande part au succès de ce travail que je leur dédie en espérant avoir été à la hauteur..

A mes très chers parents,
à mes très chers frères et sœurs,
à DAomar Mohammed Yahiaoui,
à ma très chère « Naziha » pour son amour et soutien illimités,
à mes neveux et nièces et tous ceux qui me sont chers.

Sommaire

Introduction.....	1
--------------------------	----------

Chapitre 1 : La télédétection passive et active en météorologie
--

1.1. Préambule.....	5
1.2. Acquisition des images météorologiques.....	6
1.3. L'imagerie satellitaire multispectrale	6
1.4. Les satellites météorologiques.....	7
1.5. Le satellite METEOSAT.....	9
1.5.1. Le satellite METEOSAT de première génération.....	10
1.5.2. Le satellite METEOSAT seconde génération.....	12
1.5.2.1. Caractéristiques des satellites MSG	13
1.5.2.1.1. Le radiomètre GERB	13
1.5.2.1.2. L'imageur SEVIRI	13
1.5.2.2. Principe d'acquisition des images MSG	14
1.5.2.3. Les différents canaux du radiomètre SEVIRI.....	15
1.5.2.3.1. Les canaux visibles : VIS 0.6 et VIS 0.8.....	15
1.5.2.3.2. Le canal visible à haute résolution : HRV 0.7.....	15
1.5.2.3.3. Les canaux vapeur d'eau : WV 6.2 et WV 7.3.....	15
1.5.2.3.4. Les canaux infrarouges	16
1.5.2.4. Les différents types de données	19
1.5.2.4.1. Calcul de la radiance	19
1.5.2.4.2. Calcul de la température de brillance	19
1.5.2.4.2. Calcul de la réflectance	20
1.5.2.5. Les compositions colorées des images MSG.....	21
1.6. Le radar météorologique	22
1.6.1. Principe de fonctionnement	22
1.6.2. Détection des précipitations.....	23
1.6.2.1. Puissance rétrodiffusée	23
1.6.2.2. Réflectivité radar	24
1.6.2.3. Facteur de réflectivité et intensité de précipitations	25
1.6.3. Le radar météorologique de Sétif.....	25
1.7. Discussion	27

Chapitre 2 : Méthodes d'Analyse et classification des images satellitaires

2.1. Préambule.....	28
2.2. Méthodes d'analyse d'images multispectrales	29
2.2.1. Approche spatio-fréquentielle.....	29
2.2.2. Approche structurelle	30
2.2.3. Approche statistique.....	30
2.2.3.1. Analyse basée sur l'extraction des paramètres statistiques.....	31
2.2.3.2. Analyse basée sur la modélisation spatiale	31
2.3. Méthodes de classification des images multispectrales	31
2.3.1. Classification par minimisation de distance	32
2.3.1.1. Classification par la méthode des K plus proches voisins (k-ppv).....	32
2.3.1.2. Méthode des K-means	33
2.3.1.3. Classification par Fuzzy-C-Means	33
2.3.1.4. Classification par la technique ISODATA	34
2.3.2. Classification par la méthode des hypercubes (parallélépipède)	34
2.3.3. Classification par maximum de vraisemblance	35
2.3.4. Classification par les Machines à Support Vecteurs (SVM).....	36
2.3.5. Classification par les réseaux de neurone.....	37
2.3.6. Classification par les Champs de Markov (MRF)	39
2.4. Discussion	40

Chapitre 3: Classification d'images MSG par une approche Markovienne multispectrale

3.1. Préambule.....	43
3.2. Description de la méthode.....	44
3.2.1. Principe de la classification Markovienne multispectrale	44
3.2.1.1. Estimation Bayésienne.....	45
3.2.1.2. Estimateur du maximum à postériori	46
3.2.2. Modèle Markovien de classification d'images multispectrales	47
3.2.2.1. Modélisation des champs des observations	47
3.2.2.2. Modélisation des champs des classes	49
3.2.2.3. Fonction d'énergie globale	51
3.2.2.4. Optimisation de la probabilité à postériori	52
3.3. Application de la méthodes aux images MSG	54
3.3.1. Présentation des données	54

3.3.2. La composition colorée	56
3.3.3. Résultats et interprétation	57
3.3.4. Evaluation de la méthode	67
3.4. Discussion	71

Chapitre 4 : Méthode classification des nuages selon leur contenu en eau

4.1. Préambule.....	72
4.2. Présentation du site	73
4.3. Présentations des données utilisées	74
4.4. Co localisation des données Radar et Satellite	74
4.5. Différenciation des taux de précipitations	75
4.6. Présentation et méthodologie de la technique élaborée	76
4.6.1. Description du premier modèle de classification (MLP-S).....	77
4.6.1.1. Choix des paramètres spectraux (couche d'entrée)	77
4.6.1.2. La couche de sortie	80
4.6.1.3. La couche cachée.....	81
4.6.2 Description du deuxième modèle de classification (MLP-ST).....	81
4.6.2.1. Modélisation avec des attributs du premier ordre (MLP-ST1)	81
a) Choix et sélection des attributs de texture	82
b) Critère basé sur la corrélation entre attributs	82
4.6.2.2. Modélisation avec des attributs du deuxième ordre (MLP-ST2)	85
4.6.2.2.1. Paramètres utilisés pour le calcul de la matrice de cooccurrence.....	85
a) Choix de la taille de la matrice de cooccurrence	85
b) Choix de la taille de fenêtre.....	85
c) Choix de la direction	86
d) Choix de la distance entre pixels	87
4.6.2.2.2. Choix et sélection des attributs de la matrice de cooccurrences.....	87
4.7. Résultats de la classification et évaluation des performances.....	89
4.7.1. Résultats de la classification avec le modèle (MLP-S).....	89
4.7.1.1. Application du modèle à une seule situation de précipitations	89
4.7.1.2. Application du modèle à une période de situations.....	92
4.7.2. Résultats de la classification avec le modèle (MLP-ST1).....	93
4.7.2.1. Application du modèle à une seule situation de précipitations	93
4.7.2.2. Application du modèle à une période de situations.....	95

4.7.3. Résultats de la classification avec le modèle (MLP-ST2).....	96
4.7.3.1. Application du modèle à une seule situation de précipitations	96
4.7.3.2. Application du modèle à une période de situations.....	97
4.8. Comparaison de la technique avec la méthode PRI	103
4.9. Discussion	104
Conclusion	106
Annexes	108
Bibliographie	

INTRODUCTION

La télédétection satellitaire constitue un vaste champ d'études dans plusieurs domaines et dont les retombées sont nombreuses et variées. Les différents progrès technologiques enregistrés ces dernières années à travers la multiplication de capteurs de plus en plus sophistiqués, ont permis l'acquisition d'un très grand nombre d'images caractérisées par une résolution spectrale, spatiale et temporelle très élevée telle que les images multispectrales collectées par le satellite MSG.

L'un des plus grands domaines d'application de ces images est l'étude de l'atmosphère et plus particulièrement la climatologie et la météorologie considérées comme étant des champs très vastes pour mener des recherches sur plusieurs phénomènes et paramètres météorologiques notamment les nuages et les précipitations dont l'étude et l'analyse se sont sensiblement accrues ces dernières années.

Dans le domaine du traitement d'image, la classification est considérée comme une étape très importante avant toute prise de décision conséquence d'une interprétation d'un événement décrit par une scène donnée. Elle consiste à exploiter une information extraite de l'image à interpréter afin d'identifier les différentes régions d'intérêt ou classes qui la constituent. L'exactitude de cette interprétation est conditionnée par la qualité de la classification à effectuer.

La grande diversité des méthodes de classification rend difficile le choix de celle à utiliser dans une application donnée. Chacune est adaptée au type d'images à traiter. Les résultats obtenus peuvent varier remarquablement d'une méthode à une autre. Donc, il n'existe pas de méthodes de classification universelles. Le choix d'une technique dépend de plusieurs paramètres tels que la nature de l'image et les primitives à extraire.

Les images multispectrales sont caractérisées par une très grande richesse d'information qui rend leurs traitements de plus en plus difficiles à effectuer. L'exploitation correcte de ces données permet d'identifier les différents types de nuages et de les classer en différents groupes.

Le problème de la classification des nuages à partir des images satellitaires a fait l'objet de plusieurs études scientifiques moyennant un certain nombre de méthodes selon l'objectif recherché ([Gath et Geva 1989](#) ; [Saarinen 1994](#) ; [Cheng et 2000](#); [Martinez-Uso et al 2005](#) ; [Camps-Valls et al 2006](#) ; [Li et Xiao 2007](#) ;[Kwork et al 2009](#) ; [Feng et Licheng 2011](#)).

La plus part ces méthodes ne prennent pas en considération les corrélations spectrales et spatiales qui peuvent exister entre les différents pixels de l'image. Elles sont souvent basées sur des données spectrales prises dans différentes longueurs d'onde. Ces données spectrales ont donc besoin d'être associées à d'autres types de paramètres tel que les paramètres de texture, afin d'améliorer le résultat de la classification ([Gu et al 1991](#) ; [Uddstrom et Gray 1996](#) ; [Ameur et al. 2004;2006](#) [Kaur et Ganju 2008](#); [Giannakos et Feidas 2013](#)).

La mise au point d'une approche basée sur une association des informations spectrales et texturales issues des images satellitaires peut être envisagée comme une solution pour atteindre ce but. Il est donc nécessaire d'élaborer d'autres méthodes qui exploitent conjointement ces deux types d'information pour avoir une bonne qualité de classification.

L'objectif de cette thèse est de contribuer à l'extraction et l'identification des différentes classes présentes sur les images satellitaires à travers deux études.

La première consiste à élaborer une méthode de classification d'images météorologiques multispectrales permettant d'identifier le contenu d'une scène donnée à travers les différentes surfaces qui la constituent et plus particulièrement les nuages d'eau. Cette technique est basée sur une modélisation par champs de Markov (MRF) ayant l'avantage d'introduire des interactions à l'échelle du voisinage qui constitue une notion de base en imagerie. Elle est associée à une stratégie vectorielle qui permet de prendre en considération les interactions présentes entre les différentes composantes spectrales.

La deuxième consiste à développer et à mettre en œuvre une autre méthode de classification des nuages selon leur contenu en eau. Elle est basée sur une implémentation avec les réseaux de neurone perceptrons multicouches (MLP) en prenant en considération l'utilisation conjointe de l'information spectrale et texturale de l'image multispectrale.

Les données utilisées proviennent du satellite (MSG) qui assure une couverture permanente de la totalité de la zone d'étude considérée. L'apprentissage des réseaux de

neurones a été réalisé en utilisant une base de données constituée d'images MSG et des images radar collectées par le radar de Sétif prises pendant la période comprise entre Novembre 2006 à Mars 2007. La validation de la méthode a été réalisée avec les mêmes types des images, mais prises pendant la période qui s'étend de Novembre 2010 à Mars 2011.

Notre mémoire de thèse est structuré en quatre chapitres et présenté comme suit:

Le premier s'intéresse au contexte dans lequel s'inscrit ce travail. Il donne une présentation générale sur la télédétection passive et active, suivie d'une description des différents dispositifs d'acquisition d'imagerie satellitaire et radar utilisés le domaine de la météorologie sur lequel sont orientés nos travaux de recherches. Il s'agit du satellite Météosat (MSG) mis en place par l'agence européenne EUMETSAT et le radar météorologique.

Le deuxième chapitre est une présentation d'un état de l'art des principales méthodes disponibles et les plus souvent utilisées dans le cadre d'analyse et de classification des images multispectrales. Il décrit succinctement le principe de fonctionnement de chacune d'elle en indiquant leurs avantages et inconvénients afin de mieux choisir la méthode la plus adaptée à notre problématique.

Le troisième chapitre est dédié à la présentation de la méthode de classification que nous avons élaborée pour la classification des images multispectrales. Elle a pour objectif la détection des différentes classes d'une image MSG notamment les nuages. Cette technique basée sur une modélisation markovienne qui exploite la notion de voisinage entre pixels est associée à une stratégie vectorielle des différentes composantes spectrales de l'image à traiter.

Le quatrième chapitre est consacré à la présentation et la description d'une autre méthode de classification du même type d'images. Elle est utilisée pour séparer les nuages détectés dans une image en différentes classes selon leur contenu en eau. A travers ce chapitre, nous allons présenter les trois implémentations de cette technique conçues à base de réseaux de neurones multicouches.

Enfin, nous allons clore ce mémoire par une conclusion qui synthétise les points importants des approches développées permettant de rappeler les principales contributions engendrées par ce travail et de proposer des perspectives, des pistes de recherche ainsi que les extensions que nous envisageons dans l'avenir pour continuer les travaux entrepris.

CHAPITRE 1

LA TELEDETECTION PASSIVE ET ACTIVE EN METEOROLOGIE

1.1. Préambule

La télédétection est actuellement présente dans plusieurs domaines à travers les nombreux services et avantages qu'elle nous offre. Son principe de base est de recueillir un certain nombre d'informations qui peuvent être exploitées dans différentes applications et qui se sont multipliées à travers les années ([Bonn et Rochon 1992](#) ; [Caloz et Collet 2001](#)).

La diffusion accélérée et l'augmentation de la puissance des ordinateurs contribuent de façon continue à promouvoir de nouvelles méthodes d'utilisation des données toujours plus abondantes que fournit la télédétection spatiale ([Girard et Girard 1999](#)). Les données météorologiques qui se présentent généralement sous forme d'images numériques, sont aujourd'hui une source indispensable de la prévision numérique du temps et du climat et font l'objet d'une assimilation directe par les modèles numériques. En fonction du but recherché, différents dispositifs peuvent être utilisés en vue de l'acquisition de ces informations.

Dans ce premier chapitre, nous décrivons dans un premier temps de façon succincte le principe d'acquisition des images multispectrales et nous donnons leurs principales caractéristiques. Dans un second temps, après présentation brève des principaux satellites météorologiques, nous décrivons les satellites METEOSAT de première et seconde génération. Une description détaillée du satellite MSG et du radar météorologique de Sétif sera ensuite donnée car ce sont les deux instruments que nous avons utilisé dans le cadre de notre travail de recherche. Les données satellitaires MSG seront utilisées pour la classification des différentes composantes qu'elles contiennent, notamment les nuages. Les données radar seront utilisées pour classer ces nuages selon leur contenu en eau.

1.2. Acquisition des images météorologiques

La télédétection spatiale utilise des techniques d'acquisition de l'information à distance basées sur les propriétés du rayonnement électromagnétique pour observer le système terre, océans et atmosphère. Les types de capteurs utilisés permettant de mesurer l'énergie réfléchie et/ou émise par ce système se sont évolués, multipliés et perfectionnés au cours du temps et ont donné lieu à deux types de télédétection :

- *la télédétection passive* qui utilise des capteurs passifs appelés « *radiomètres* », qui enregistrent le rayonnement naturel, lumière visible mais aussi infrarouge ou micro-onde, sous forme numérique ;
- *la télédétection active* qui utilise des capteurs actifs appelés « *radars* », qui émettent artificiellement un rayonnement pour en étudier les interactions avec l'objet à étudier.

Quel que soit le type du capteur utilisé, une image météorologique représente une mesure de la quantité de rayonnement électromagnétique recueilli par le capteur en ce pixel ou sur une petite zone qui l'entoure. Ce rayonnement peut être de plusieurs types:

- ✓ *le rayonnement d'origine naturelle* : qui est la réflexion partielle du Soleil par toute surface terrestre, il peut être aussi réfléchi et/ou absorbé en partie par l'atmosphère qui joue alors le rôle de filtre ;
- ✓ *le rayonnement émis par la surface terrestre* : c'est l'énergie perdue par la surface terrestre, elle est en partie absorbée par l'atmosphère ;
- ✓ *le rayonnement d'origine artificielle (radar, laser)* : qui est la réflexion par toute surface terrestre d'ondes émises par un émetteur.

Donc, dans tous les cas, il y a émission d'un rayonnement électromagnétique dans une certaine plage de longueurs d'onde.

1.3. Les images satellitaires multispectrales

Les données enregistrées délivrées par un capteur satellitaire peuvent être discrètes et se présentent comme des points échantillonnés de mesures. Ces données peuvent également correspondre à des images qui se présentent sous forme des grilles à deux dimensions, qui ont les quatre principales caractéristiques suivantes:

- *la résolution spatiale* : indique la taille du pixel de l'image. Elle correspond à l'étendue de la surface réelle visualisée sur l'image représentée par chaque pixel. Elle peut diminuer en fonction de l'altitude du capteur d'exploration et peut varier en fonction de l'angle d'observation du capteur. Pour le satellite MSG, elle est de 3km sur les canaux infrarouges thermiques, visibles et vapeur d'eau et de 1 km sur le canal HRV.
- *La résolution spectrale*: le capteur satellitaire effectue des mesures à une certaine longueur d'onde ou ensemble de longueurs d'onde. La résolution spectrale indique donc, le nombre de bandes spectrales dans lesquelles le capteur peut capturer les radiations. Le satellite MSG dispose de 12 bandes spectrales. Le nombre de bandes n'est pas le seul aspect important de la résolution spectrale. La position des bandes dans le spectre électromagnétique est un aspect très important.
- *La résolution temporelle*: précise la fréquence de révision du satellite pour un emplacement spécifique. En effet, les systèmes embarqués à bord des satellites, permettent d'observer la surface terrestre avec une plus ou moins grande régularité temporelle. Le satellite MSG fournit une image toutes les 15 minutes. Le facteur temps est important surtout pour les phénomènes à court terme (inondations, marées noires, etc.), les phénomènes atmosphériques qui changent rapidement et les nuages persistants qui offrent une vue directe limitée de la surface de la Terre.
- *La résolution radiométrique* : c'est la sensibilité d'un détecteur aux variations de l'intensité de l'énergie électromagnétique émise, réfléchie ou diffusée détectée. Les différents niveaux d'intensité peuvent être discriminés par le capteur dans une bande.

Le progrès technologique inévitable et irrésistible au cours des dernières années, a conduit à l'émergence des capteurs embarqués sur les satellites et à l'amélioration continue de ces différentes résolutions, ce qui a un effet positif sur le niveau de détail, l'exactitude et la quantité d'information permettant l'utilisation de ces images dans différents domaines.

1.4. Les satellites météorologiques

Les satellites météorologiques sont indispensables pour la collecte des données utilisées dans les domaines de la climatologie et de la météorologie. Leur principale mission consiste à l'observation continue de l'atmosphère terrestre et la détection du rayonnement et de l'énergie

thermique de l'atmosphère et des surfaces sous-jacentes. Ils génèrent des images de la planète entière sur une base complètement opérationnelle et de les renvoyer vers la terre et peuvent aussi, déterminer la température et le contenu de vapeur d'eau à diverses altitudes dans l'atmosphère. Les observations satellitaires constituent un moyen très important pouvant aider les prévisionnistes à surveiller le temps et le climat de la terre et reconnaître le développement de phénomènes météorologiques susceptibles de causer des catastrophes.

Ces satellites disposent de capteurs qui réagissent à l'énergie rayonnante du soleil produisant la lumière visible qui est réfléchiée par les surfaces de la terre et les nuages et retournée au satellite et l'énergie infrarouge ou thermique émanant de surfaces dont les températures se situent à l'intérieur de la gamme de celles des surfaces terrestres ou aquatiques de la terre et des sommets de nuages. 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.

Les principales missions de la télédétection dans le domaine atmosphérique sont les satellites géostationnaires (MSG) pour les prévisions en temps réel (*nowcasting*) et les satellites polaires (ESA, NASA) qui se caractérisent par une meilleure résolution spatiale. Le premier satellite météorologique qui a commencé à transmettre une imagerie nuageuse simple mais utile est lancé par les Etats Unis le 1er avril 1960. Par la suite, et plus exactement en 1969, l'URSS lança le premier d'une série de satellites polaires.

Afin de coordonner la dynamique issue de l'évolution rapide des satellites, un système a été mis en place par les membres du Groupe de Coordination des Satellites Météorologiques (GCSM). Ainsi, quatre opérateurs satellitaires à savoir : EUMETSAT (Europe), JAXA (Japon), FKA (Russie) et NASA (Etats-Unis) se partagent la responsabilité de ce réseau opérationnel de satellites météorologiques.

Comme le montre la figure1, le système mondial de satellites météorologiques opérationnels est composé d'au moins cinq satellites régulièrement espacés autour de l'équateur en orbite géostationnaire, et au moins deux satellites en orbite quasi polaire.

La complémentarité qui existe entre ces deux types de satellites permet au système d'assurer les tâches opérationnelles de base. Les satellites polaires portent une plus grande variété d'instruments que les satellites géostationnaires et peuvent observer la planète avec

plus de précision, mais moins fréquemment




Figure 1.1 : Le Système mondial de satellites météorologiques (Source Eumetsat).

1.5. Le satellite METEOSAT

En télédétection spatiale, les images et animations issues des satellites météorologiques géostationnaires tels que les satellites européens de la série Météosat, sont les documents de télédétection les plus utilisés et diffusés auprès du grand public.

Situés à environ 36000 km d'altitude au-dessus de l'équateur, le champ visuel des satellites METEOSAT couvre l'Afrique, l'Europe et les extrémités de l'Asie et de l'Amérique méridionale. Ils ont une vitesse de rotation angulaire identique à celle du globe terrestre (Figure 1.2), ce qui les rend immobiles au dessus d'un point unique de la terre. Les images acquises par ces satellites couvrent toujours la même zone du globe terrestre durant un intervalle de temps fixé à l'avance.

Le système METEOSAT permet de fournir des données satellitaires rentables et des services annexes qui correspondent aux besoins des Etats membres d'EUMETSAT. Il permet également, dans la mesure du possible, de répondre aux besoins exprimés par l'Organisation Météorologique Mondiale.

Ce système joue un véritable rôle international car il offre ses données et services à tous les pays du monde capables de les recevoir. Ces données et services sont utilisés

principalement dans la prévision quotidienne du temps par le suivi en temps réel des masses nuageuses et des phénomènes météorologiques. Elles peuvent aussi être utiles dans tous les secteurs de la météorologie tels que : la météorologie marine, l'agro météorologie et la météorologie aéronautique, ainsi que pour beaucoup d'autres disciplines, en particulier la climatologie et la surveillance de la planète Terre.

La figure suivante explique le concept de fonctionnement de ce satellite et sa position par rapport à la surface terrestre :




Figure 1.2 : Concept du satellite METEOSAT (source Eumetsat).

Le programme est opérationnel depuis 1970. La première série de ce système est la série de satellites METEOSAT première génération qui a été en orbite pendant 23 années qui est constituée sept satellites lancés entre 1977 et 1997, puis continuée actuellement par la deuxième génération de METEOSAT (MSG).

1.6. Le satellite METEOSAT de première génération

Le principal instrument de ce satellite est le radiomètre MVIRI qui dispose essentiellement de trois canaux suivant :

- un canal visible (VIS) qui représente une bande panchromatique qui inclut la totalité de la bande spectrale du visible et la partie proche de la bande infrarouge,
- un canal infrarouge (IR) représentant une bande thermique,
- un canal vapeur d'eau (WV) qui représente une bande infrarouge moyenne.

Les principales caractéristiques de ces trois bandes sont rapportées dans le tableau suivant :

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

Tableau 1.1 : Les canaux de METEOSAT première génération

Sensible au rayonnement émis par la surface de la terre, ce capteur fournit les données de base issues des rayonnements du spectre électromagnétique dans les domaines visible et infrarouge. La radiation incidente est filtrée dans un premier temps dans le radiomètre, puis transformée dans un second temps en signal électrique proportionnel à l'énergie de la radiation ([Eumetsat](#)). Ce signal est codé sur 8 bits soit des entiers dont la valeur décimale est comprise entre 0 et 255. Des images correspondant à trois bandes spectrales différentes sont ainsi disponibles à chaque acquisition du satellite.

Comme le montre la figure 1.3, 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.




Figure 1.3 : Le satellite METEOSAT (source Eumetsat).

Le dernier satellite de cette première génération est le satellite METOSAT-7 qui a un poids réduit avec une masse de 720 kg et une durée de vie de 5 ans. Il est opérationnel à 0° de longitude au-dessus du golfe de Guinée.

1.7. Le satellite METEOSAT seconde génération

La famille des satellites MSG est constituée de quatre satellites météorologiques placés en orbite géostationnaire. Ils sont développés sous la responsabilité de l'Agence Spatiale Européenne pour le compte de l'organisation météorologique européenne EUMETSAT dans le but d'assurer la relève de la série des satellites METEOSAT première génération. Le programme MSG permet d'avoir une amélioration de l'imagerie et d'analyser les masses d'air. Ces satellites doivent, à leur tour, être remplacés par les satellites Météosat troisième génération (MTG) à partir de 2018.



Figure 1.4: Satellite MSG1 (source Eumetsat).

Comme pour ceux de la première génération, les données brutes collectées par ces satellites sont transmises au niveau de la station Eumetsat située Darmstadt en Allemagne. Par la suite, ces images subissent des traitements, tel que des corrections géographiques, de façon que les images soient superposables au pixel près, ainsi que des prétraitements pour la calibration des radiomètres, avant de les diffuser par deux canaux de dissémination du satellite ([Eumetsat](#)).

Parmi les très nombreuses tâches que les satellites MSG permettent de réaliser dans le domaine de la météorologie, on peut citer :

- la collection des images multispectrales destinées à fournir des images électroniques des nuages et des surfaces terrestres et marines,
- l'analyse des masses d'air pour surveiller l'état thermodynamique dans la partie basse de l'atmosphère,
- la fourniture des images à haute résolution pour suivre l'évolution des nuages convectifs, avec une résolution de 1 km,

- l'extraction des paramètres météorologiques, tels que la vitesse du vent, les températures de surface de la mer et des sols...,
- la dissémination pour transmettre ces données à la communauté des utilisateurs, le satellite jouant ainsi un rôle de satellite de télécommunications,
- la collecte et relais de données d'environnement transmises par des plates-formes automatiques (balises marines, terrestres et aéroportées...).

1.7.1. Caractéristiques des satellites MSG

Les deux principaux éléments de cette famille de satellites sont : le radiomètre SEVIRI (Spinning Enhanced Visible and InfraRed Imager) et le GERB (Geostationary Earth Radiation Budget experiment).

1.7.1.1. Le radiomètre GERB

Cet instrument qui mesure des radiations émises par la terre utiles pour caractériser les masses d'air est un transpondeur capable de repérer les signaux de détresse et les relayer au sol. Le bilan radiatif qui représente le rapport entre la quantité d'énergie reçue du Soleil par notre planète et la quantité d'énergie rayonnée en retour, joue un rôle très important dans l'équilibre climatique de notre planète. Ce rapport qui était élevé avec Météosat première génération, a été amélioré grâce à l'élargissement des bandes spectrales.

1.7.1.2. L'imageur SEVIRI

Ce radiomètre imageur plus sophistiqué que le MVIRI, réalisé par Matra, dispose de 12 canaux contre 3 pour la précédente génération. Il fournit des images de l'hémisphère observé par le satellite dans douze bandes spectrales différentes, tous les quarts d'heure, au lieu de 30 minutes avec Météosat première génération, soit deux fois plus fréquemment.

L'augmentation du spectre des observations de 3 à 12 et la réduction du temps de rafraîchissement des données de 30 à 15 minutes est une avancée majeure. Ceci permet aux climatologues et aux météorologues d'une part, d'améliorer les modèles météorologiques numériques et d'autre part, de détecter plus facilement le déclenchement des phénomènes à évolution rapide tels que : les orages, les tempêtes de neige ou les bancs de brouillard... De plus, une résolution au sol de 1 km dans le spectre visible au lieu de 2,5 km précédemment permet d'observer et de suivre des phénomènes localisés ([Eumetsat](#)).

1.7.2. Principe d'acquisition des images MSG

Le capteur SEVIRI est un radiomètre à balayage et c'est la rotation du satellite autour de son axe principal d'inertie qui est utilisée pour réaliser l'acquisition des images.

Le satellite tourne à 100 tours par minute autour d'un axe parallèle à l'axe Nord-Sud de la terre. Le télescope du radiomètre de Météosat vise la terre par l'intermédiaire d'un miroir et balaie à chaque révolution du satellite une étroite bande de la surface de la terre. L'angle de balayage correspondant, de 18° , est décrit en 30 ms. Pendant les 570 ms suivantes, le télescope vise l'espace et cette durée est mise à profit pour modifier l'orientation du miroir, de façon qu'au tour suivant, il balaie au sol une bande contiguë à la précédente, mais plus au nord. La phase de non acquisition de données est mise à profit pour calibrer les détecteurs (Eumetsat 2004). Le radiomètre balaye la surface de la terre ligne par ligne. Chaque ligne consiste en une série d'images élémentaires ou pixel. Pour chaque pixel, le radiomètre mesure l'énergie radiative dans différentes bandes spectrales.




Figure 1.5: Principe d'acquisition de l'image de la terre

Cette mesure est numérisée, puis transmise à une station au sol où elle est traitée, avant d'être envoyée à la communauté des utilisateurs.

1.7.3. Les différents canaux du radiomètre SEVIRI

Sur les 12 canaux dont dispose le radiomètre SEVIRI, trois sont consacrés à la lumière visible, dont un en haute résolution, avec des détails aussi fins qu'un kilomètre et huit travaillent dans l'infrarouge dans différentes longueurs d'onde apportant de très nombreuses informations sur l'état de l'atmosphère qui étaient alors difficilement détectables avec la précédente génération d'instruments. En combinant les différentes longueurs d'onde, les prévisionnistes ont accès à une description plus fine des processus qui agitent l'atmosphère.

Le tableau 1.2 synthétise les principales caractéristiques des 12 bandes spectrales de MSG et leurs différentes utilisations dans le domaine de la météorologie. Quelques précisions sur les différentes informations issues de ces bandes spectrales sont présentées ci-dessus :

1.7.3.1. Les canaux visibles

Le satellite MSG possède deux bandes spectrales dans le visible: le canal VIS0.6 et le canal VIS0.8 qui sont principalement utilisés dans la détection et le suivi des masses nuageuses ainsi que la surveillance de la surface des terres et des aérosols. Ils permettent aussi de discriminer les nuages d'eau des nuages de glace et des océans et de détecter les surfaces couvertes de neige et de glace. Les images provenant de ces deux canaux peuvent être interprétées de la même façon que celles issues du canal visible de Météosat première génération car elles ont des caractéristiques similaires. La combinaison entre ces deux canaux permet d'établir les indices de végétation.

1.7.3.2. Le canal visible à haute résolution

En complément des deux canaux visibles, le satellite MSG dispose d'un autre canal visible caractérisé par sa large bande (HRV 0.7). Il est sensible à toutes les longueurs d'onde du visible, possède une résolution spatiale de 1km améliorée par rapport aux autres canaux et permet une observation bien plus détaillée des surfaces. Il est utilisé pour la mesure de la vitesse du vent à l'altitude des nuages ainsi pour distinguer leur texture.

1.7.3.3. Les canaux vapeur d'eau : WV 6.2 et WV 7.3

Les données acquises dans ces bandes vapeur d'eau sont très utiles pour l'analyse et les prévisions météorologiques à l'échelle synoptique. Elles donnent des informations sur la

teneur et la répartition verticale de l'humidité dans les hautes couches de l'atmosphère. Ces deux canaux permettent de mesurer le contenu en vapeur d'eau à différents niveaux de la troposphère. Les formations particulièrement chargées en vapeur d'eau apparaissent en noir. Le canal 6,2 μ m renseigne essentiellement sur le contenu en vapeur d'eau des plus hautes couches de l'atmosphère, alors que le canal 7,3 μ m est sensible au contenu vapeur d'eau aussi bien dans les moyennes que les hautes couches atmosphériques.

1.7.3.4. Les canaux infrarouges

C'est dans l'infrarouge que les bandes spectrales sont plus nombreuses. Pas moins de sept canaux, dont les caractéristiques sont présentées ci-dessous, se répartissent dans cette partie ([Eumetsat](#)):

- ❖ *Le canal IR 1.6* qui se situe dans le proche infrarouge du spectre électromagnétique permet de détecter les surfaces couvertes de neige et de glace qui apparaissent en noir sur les images issues de ce canal. Il est utilisé également pour discriminer les nuages d'eau des nuages de glace et les surfaces nuageuses des surfaces neigeuses. De plus, il fait une meilleure distinction des surfaces émergées, car les sols et la végétation ont une réflectance plus importante dans le PIR que dans le visible.
- ❖ *Le canal IR 3.9* qui se situe dans le moyen infrarouge du spectre électromagnétique. Le signal mesuré au niveau de ce canal provient aussi bien du rayonnement solaire réfléchi par les surfaces que le rayonnement thermique émis par ces mêmes surfaces, où la lumière du soleil influe sur le rayonnement reçu. L'interprétation des images provenant de ce canal nécessite quelques précautions à cause de l'influence du soleil sur le rayonnement reçu. En effet, durant le jour, l'énergie solaire réfléchie domine pour donner l'apparence d'une image dans la partie visible du spectre, tandis que la nuit, l'énergie ne provient que de la Terre avec les caractéristiques de la partie infrarouge du spectre. Ce canal est très intéressant pour détecter les nuages bas et les brouillards, pour mesurer les températures de surface du sol et de la mer - uniquement pendant la nuit - ou encore pour détecter les incendies de forêt.
- ❖ *Le canal IR 8.7* permet de discriminer entre les nuages de glace et les nuages d'eau et donne des informations sur les masses nuageuses minces des cirrus.

- ❖ *Le canal IR 9.7* est utilisé pour mesurer l’ozone total et évaluer sa variabilité diurne ainsi que pour établir les configurations d’ozone comme indicateurs des champs de vents à ce niveau.
- ❖ *Les canaux IR 10.8 et IR 12.0* qui sont situés dans l’infrarouge thermique mesurent le rayonnement émis par les nuages et la surface terrestre qui renseigne sur leur température. Ils permettent d'estimer l'altitude du sommet des nuages, le suivi des nuages, la détermination des vents atmosphériques et l'estimation de l'instabilité atmosphérique. En l’associant à une image visible, l’information issue du canal IR10.8 permet aux météorologues de déterminer les genres des nuages détectés.
- ❖ *Le canal IR 13.4* est utilisé pour l’estimation de l’instabilité atmosphérique et fournit des informations sur la température de la basse troposphère. Il est situé dans la partie du spectre où le rayonnement est absorbé par les molécules de dioxyde de carbone.

N°	Nom du canal	Longueur d'onde centrale (µm)	Bande Spectrale (µm)	Utilisation
1	VIS 0.6	0.635	0.56-0.71	Détection et suivi des masses nuageuses, étude des terres émergées
2	VIS 0.8	0.81	0.74-0.88	Détection et suivi des masses nuageuses, étude des terres émergées
3	PIR 1.6	1.64	1.50-1.78	Distinction nuages d'eau et de glace, distinction neige / nuages chargés d'eau
4	IR 3.9	3.92	3.48-4.36	Détection des nuages bas et brouillards nocturnes, températures de surface, incendies de forêts
5	WV 6.2	6.25	5.35-7.15	Mesure de la vapeur d'eau dans la haute troposphère, instabilités atmosphériques et vents locaux
6	WV 7.3	7.35	6.85-7.85	Mesure de la vapeur d'eau dans la moyenne troposphère, instabilités atmosphériques et vents
7	IR 8.7	8.7	8.30-9.10	Détection des cirrus, instabilités atmosphériques
8	IR 9.7	9.66	9.38-9.94	Mesure de l'ozone
9	IR 10.8	10.8	9.80-11.80	Détection des nuages, températures des surfaces terrestres et océaniques, instabilités atmosphériques
10	IR 12.0	12	11.00-13.00	Détection des nuages, températures des surfaces terrestres et océaniques, instabilités atmosphériques
11	IR 13.4	13.4	12.40-14.40	Détermination de la hauteur des cirrus, instabilités atmosphériques
12	HRV	0.7	0.50-0.90	Détection et suivi des masses nuageuses, étude des terres émergées

Tableau 1.2 : Principales caractéristiques et utilisations de l'instrument SEVIRI(Eumetsat)

La figure 1.6 montre un exemple d'image fournie par chacune des douze bandes spectrales du radiomètre SEVIRI du satellite MSG :




Figure 1.6 : les douze bandes spectrales de SEVIRI (Source [Eumetsat](#))

1.7.4. Les différents types de données

Le satellite MSG fournit deux types de fichiers images: le premier type (image 1.0) représente l'image acquise sous sa forme brute n'ayant subi aucun prétraitement et le deuxième type (image 1.5) représente l'image corrigée géométriquement de toutes les perturbations introduites par le satellite (Lacaze et Bergès, 2005).

1.7.4.1. Calcul de la radiance (Ra)

Le calcul de la radiance de chaque pixel se fait en utilisant l'image (Level 1.5) et les coefficients de calibration. La valeur « count » de chaque pixel de l'image initiale est convertie en radiance exprimée en $\text{mWm}^{-2}\text{sr}^{-1}(\text{cm}^{-1})^{-1}$ en utilisant l'équation suivante [Eumetsat 2004] :

$$Ra(i, ch) = CN(i, ch) \cdot slope(ch) + offset(ch) \quad (1.1)$$

Où :

- $CN(i, ch)$ est le compte numérique d'un pixel i pour un canal ch qui peut prendre des valeurs allant de 0 à 1023,
- $offset(ch)$ et $slope(ch)$ sont des coefficients de calibration exprimés en $\text{mWm}^{-2}\text{sr}^{-1}\text{cm}^{-1}$ utilisés pour calculer la radiance à chaque pixel d'un canal ch . Leurs valeurs sont précisées à l'entête de chaque image (Eumetsat 2004).

La valeur de radiance peut à son tour être convertie en température de brillance dans les canaux infrarouges et en réflectance dans les canaux visibles [Eumetsat 2004].

1.7.4.2. Calcul de la température de brillance (Tb)

La température de brillance Tb exprimée en kelvin est calculée pour chaque pixel dans les canaux infrarouges à partir de la formule de Planck (5.2) suivante :

$$Tb = \frac{c_2 v_c}{\left(\log\left(\frac{c_1 + v_c^3}{Ra} + 1 \right) - B \right) \cdot A} \quad (1.2)$$

Où:

- $c_1 = 1,19104 \cdot 10^{-5} \text{mWm}^{-1}\text{sr}^{-1}(\text{cm}^{-1})^{-4}$,
- $c_2 = 1,43877\text{K}(\text{cm}^{-1})^{-1}$
- 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 (Tableau 1.3).

N° du canal	Canal	Vc	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

Tableau 1.3 Valeurs des constantes A et B en fonction des canaux infrarouges.

1.7.4.3. Calcul de la réflectance (Re)

Elle est exprimée en (%) et calculée pour les canaux ($VIS0.6$, $VIS0.8$, $NIR1.6$, HRV) selon équation suivante :

$$Re = \frac{\pi \cdot Ra \cdot d^2(t)}{I \cdot \cos(\theta(t, x))} \cdot 100 \quad (1.3)$$

Où

- Ra est la radiance du pixel calculée par l'équation (5.1),
- $d(t)$ est la distance terre-soleil à l'instant t (calculée en fonction de la date),
- I est une constante dépendant du canal d'observation (Table 5.2), 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(HRV0.7)
I	65.2296	73.0127	62.3715	78.8952

Tableau 1.4 : Valeurs de la constante I en fonction du canal

1.7.5. Les compositions colorées des images MSG

Le principe des compositions colorées consiste à produire des images couleurs en fonction de la signature spectrale des différents objets présents dans une image. Elles permettent de distinguer les différentes surfaces des images multispectrales afin de faciliter l'analyse et l'interprétation. Le principe d'une composition colorée est d'attribuer à chacune des trois couleurs primaires (Rouge, Vert et Bleu), une bande spectrale du satellite MSG.

Un exemple d'une composition colorée est donné dans la figure 1.7. Elle est réalisée en assignant trois bandes spectrales IR1.6, VIS0.6 et VIS0.8 respectivement aux composantes rouge vert et bleu. Les images utilisées ont été collectées par le satellite MSG le 24/11/2012 à 11h45. Elles nous ont été fournies par l'ONM (Office National de Météorologie) d'Alger.




Figure 1.7 : Image en fausses couleurs réalisée par une combinaison de trois bandes du satellite MSG (([Eumetsat](#))).

Plusieurs autres compositions colorées peuvent être réalisées à partir de onze bandes spectrales du satellite MSG. Généralement, seules les bandes spectrales présentant des caractéristiques physiques différentes peuvent être combinées. Quelques combinaisons standards recommandées par EUMETSAT utilisées pour le suivi de certains phénomènes naturels et l'étude des surfaces terrestres sont données dans le tableau 1.5 suivant :

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

Tableau 1.5 : Les différentes combinaisons colorées standards issues du satellite MSG

1.8. Le radar météorologique

1.8.1. Principe de fonctionnement

Le radar (Radio Detection And Ranging) est un instrument de détection et de mesure composé essentiellement d'un émetteur, d'une antenne et d'un récepteur. Son principe de fonctionnement est basé sur l'émission régulière de très brèves impulsions électromagnétiques de forte puissance et de longueur d'ondes allant du mm à la dizaine de km. Une diffusion des ondes incidentes dans toutes les directions est provoquée à la rencontre d'un obstacle. Le signal utile représente une partie de ce signal diffusé et renvoyé vers le radar.

La largeur du faisceau θ est définie par le diamètre de l'antenne (D) ainsi que la longueur d'onde émise (λ) comme suit (Battan, 1959) :

$$\theta = 0,85.(\lambda / D) \quad (1.4)$$

La localisation d'un obstacle nécessite la connaissance permanente de l'orientation de l'antenne et les angles de site (α) et d'azimut(β), la mesure de l'intervalle de temps (t_r) entre

l'émission du train d'ondes et la réception du signal réfléchi. L'obstacle est caractérisé par la puissance du signal réfléchi.




Figure 1.8 : Le balayage du radar et le domaine spatial étudié

Initialement, et plus précisément pendant la seconde guerre mondiale, la technique du radar a été développée dans le domaine militaire dans le but de détecter des avions. Les précipitations ont été considérées comme étant un bruit perturbant la détection des avions ennemis. C'est pendant cette période qu'a commencé son exploitation dans le domaine de la météorologie et depuis, son utilisation n'a cessé d'évoluer, en passant d'une description qualitative à des estimations quantitatives de nombreux paramètres météorologiques (Collier 1989 ; Doviak 1993 ; Delrieu et al 1991 ; Hammouda 1995 ; 2000 ; Früh 2007).

1.8.2. Détection des précipitations

1.8.2.1. Puissance rétrodiffusée

Dans le cas des précipitations, la cible à détecter n'est pas un obstacle mais elle représente toute la partie de l'atmosphère susceptible d'être touchée par la pluie. L'énergie rétrodiffusée est égale à la somme des énergies réfléchies par chacune des gouttes appartenant au volume unitaire considéré. La puissance rétrodiffusée (Pr) représentant la grandeur mesurée expérimentalement est liée à la réflectivité radar (μ) selon la relation suivante:

$$Pr = C \cdot \mu \cdot L^2(r) / r \quad (1.5)$$

Avec : C: constante du radar.

$L(r)$: facteur d'atténuation.

r: distance au radar.

Une goutte d'eau permet de rediffuser autour d'elle une part de l'énergie incidente. Cette capacité de rétrodiffusion est caractérisée par sa surface réfléchissante efficace (σ). En supposant que la forme des gouttes d'eau est sphérique et que leur diamètre est très petit par rapport à la longueur d'onde émise par le radar, Rayleigh, définit une approximation de la section efficace d'une goutte d'eau par rapport à son diamètre par l'équation suivante :

$$\sigma = (\Pi^5 / \lambda^4) \cdot K^2 \cdot D \quad (1.6)$$

K représente la constante diélectrique de la cible qui est égale à 0.93 pour l'eau.

1.8.2.2. Réflectivité radar

Pour un volume élémentaire, contenant un grand nombre de gouttes d'eau, la capacité de rétrodiffusion de l'énergie incidente est caractérisée par la section efficace moyenne de rétrodiffusion par unité de volume. Cette valeur appelée réflectivité radar décrite par l'équation (1.7) n'est autre que la somme des sections efficaces relative à chaque goutte appartenant au volume élémentaire considéré. Cette réflectivité radar pour une unité de volume est donnée par la relation suivante :

$$\sigma = (\Pi^5 / \lambda^4) \cdot K^2 \cdot \sum D_i^6 \quad (1.7)$$

i : indice décrivant l'ensemble des gouttes.

D_i : diamètre de la goutte i .

λ : longueur d'onde du rayonnement incident.

Le facteur de réflectivité $Z = \sum D_i^6$ peut être exprimé en fonction de la répartition granulométrique $N(D)$, autrement dit spectre des gouttes d'eau comme suit:

$$Z = \int_0^{\infty} N(D) \cdot D^6 \cdot dD \quad (1.8)$$

L'intensité de la pluie (I) peut être définie comme étant le volume d'eau qui traverse une surface donnée par unité de temps. Cette intensité dépend, à la fois, du diamètre des gouttes d'eau, de leur vitesse de chute ainsi que de la répartition granulométrique du volume d'eau considéré. Elle est donc définie par :

$$Z = (\Pi / 6) \cdot \int_0^{\infty} D^3 \cdot V(D) \cdot N(D) \cdot d(D) \quad (1.9)$$

1.8.2.3. Facteur de réflectivité et intensité de précipitations

En admettant que la répartition granulométrique des gouttes varie exponentiellement ($N(D) = N_0 \cdot e^{-\lambda D}$) et que la vitesse de chute des gouttes d'eau est de la forme ($V = K \cdot D^x$), l'intensité de la pluie (I) peut être reliée directement au facteur de réflectivité (Z) par :

$$Z = a \cdot I^b \quad (1.10)$$

avec a , b sont des coefficients dépendant principalement du lieu géographique considéré, des situations météorologiques associées, de la genèse de la pluie ainsi que de plusieurs autres paramètres microphysiques et dynamiques des précipitations. Ces coefficients sont définis par différents couples de valeurs proposés par de nombreux auteurs et les plus utilisés sont:

($a = 200$ et $b = 1,6$) : pour les pluies stratiformes (loi de MARSHALL-PALMER 1955).

($a = 486$ et $b = 1,37$) : pour les pluies convectives (loi de JONES 1956).

($a = 1780$ et $b = 2,21$) : pour la neige (loi de SEKHON-SRIVASTAVA 1970).

La connaissance de la répartition granulométrique (spectre des gouttes de pluie) est très importante pour élaborer cette relation entre l'intensité des précipitations et le facteur de réflectivité. En pratique, la connaissance de ce spectre n'est pas toujours facile à réaliser.

1.8.3. Le radar météorologique de Sétif

L'acquisition et le prétraitement des images radar sont réalisés par un dispositif appelé « Système d'Acquisition Numérique pour l'Analyse des Grains Africains (SANAGA) » constitué essentiellement d'un module câblé de numérisation, d'un micro-ordinateur et d'un logiciel interactif travaillant en temps réel. C'est un système d'acquisition des données radar développé au laboratoire d'Aérodynamique de Toulouse ([S Sauvageot et Despau 1990](#)) et qui est implanté sur de nombreux radars à travers le monde dont ceux du réseau algérien.

Le radar de Sétif est l'un des sept radars météorologiques dont dispose l'Algérie. Il est situé à 1 700 m d'altitude et à la position 36° 11' N, 5° 25' E. C'est un Radar AWSR 81C en bande C, de fréquence opérationnelle de valeur de 5.6 GHz et de polarisation linéaire et horizontale. Il se déplace en azimut entre 0 à 360 degrés continus et le déplacement en inclinaison est de -20° à 90°.

Les images radar que nous avons utilisées ont une taille de 512x512 pixels collectées toutes les 15 minutes avec une résolution spatiale de 1km². Chaque pixel est codé sur 4 bits ce qui correspond à 16 classes illustrées par la figure 1.9 qui représente un exemple d'une image enregistrée par le radar de Sétif en réflectivité (en dBZ).

Le tableau 1.6 suivant montre les principales caractéristiques techniques de ce radar :

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 1.6: Caractéristiques du radar de Sétif

Le facteur de réflectivité noté (Z) est le paramètre physique représentatif de l'image radar. Il est exprimé en (mm^6m^{-3}).

➤ Calcul du taux de précipitation

Le facteur de réflectivité peut être converti en intensité de précipitations R (mm/h) en utilisant l'équation suivante :

$$Z = 300.R^{1.5} \quad (1.11)$$

Cette relation est adaptée à la situation météorologique de la région que nous avons choisie comme zone d'étude.

La conversion de cette valeur d'intensité de précipitation en dBZ est effectuée par la relation suivante:

$$Z(dBZ) = 10 \log(Z) \quad (1.12)$$

La figure suivante montre un exemple d'une image en réflectivité collectée par le radar météorologique de Sétif :




Figure 1.9 : Exemple d'une image en réflectivité issue du radar de Sétif.

1.9. Discussions

Dans ce chapitre, nous avons exposé le principe général de la télédétection passive et active. C'est un moyen d'acquisition des données que nous avons traitées dans le cadre de notre travail de recherche. Ces données représentées par des images multispectrales météorologiques, sont caractérisées par une grande richesse d'information pouvant être exploitée dans diverses applications. Ensuite nous avons fait une description du satellite MSG en donnant ses principales caractéristiques et mettant en évidence les propriétés spatiale, temporelles et spectrales du radiomètre SEVIRI. La connaissance de ces propriétés permet de faciliter la détection des différents types de nuages dans le but de calculer certains paramètres météorologiques tels que le taux de précipitations. Enfin, nous avons décrit le radar météorologique qui est un instrument de mesure des précipitations pour différencier les nuages précipitants selon leur contenu en eau. Ces deux dispositifs nous ont permis donc de collecter une base de qui a servit pour tester et valider les différentes techniques que nous avons élaborées.

Dans le chapitre suivant, nous allons décrire les principales méthodes d'analyse et de classification d'images multispectrales, les plus couramment utilisées tout en mentionnant les avantages et les inconvénients de chacune d'elles afin de nous permettre d'élaborer une méthode adaptée au type de données que nous allons traiter.

CHAPITRE 2

METHODES D'ANALYSE ET DE CLASSIFICATION DES IMAGES MULTISPECTRALES

2.1. Préambule

Une image multispectrale est une image décrivant une même scène pour une succession de longueurs d'onde dans un domaine spectral donné. Pour les rendre utilisables et exploitables, différents traitements sont indispensables après leur acquisition afin de ne conserver que les informations utiles.

Pour interpréter de telles images, une opération d'analyse doit être effectuée suivie généralement d'une classification afin de caractériser les individus appelés « pixels » en les regroupant en classes homogènes et en leur affectant éventuellement une étiquette donnée.

L'analyse d'une image multispectrale a pour objectif d'extraire le maximum d'informations pertinentes qui la caractérisent. Elle peut être utilisée dans diverses applications telles que : la compression, la segmentation ou la classification dans laquelle les informations extraites représentent des attributs qui permettent de décrire la forme des différentes régions ou classes constituant l'image à traiter. Une étude exhaustive des différentes approches d'analyse en traitement d'images est donnée dans plusieurs ouvrages tels que celui de ([Maitre 2003](#);) et celui de ([Cocquerez et Philipp 1995](#)) ou dans le cours ([E-Cours3](#)). L'analyse de texture est l'une des approches les plus utilisées et adaptées au traitement des images que nous avons utilisées.

La classification des images multispectrales fait souvent appel à l'information contextuelle de l'image telle que la texture qui présente un grand intérêt dans la réalisation de la classification ([Fortier 1999](#)). Plusieurs modèles permettant de caractériser la texture des images peuvent être utilisés pour pouvoir l'exploiter convenablement.

L'étude radiométrique du voisinage de chaque pixel permet l'extraction, à partir de l'image initiale, de nouvelles bandes qui permettent de localiser les différentes régions texturées qui la caractérisent. Ces bandes représentent ainsi de nouveaux critères qu'on peut ajouter à la signature spectrale des pixels afin d'améliorer la classification.

Dans ce chapitre, nous allons décrire de façon succincte les principales techniques d'analyse et de classification d'images multispectrales. Nous donnerons le principe de leur fonctionnement ainsi que les avantages et les inconvénients de chacune d'elle afin de choisir la méthode la plus adaptée à notre problématique.

2.2. Méthodes d'Analyse des images multispectrales

Le principal objectif de l'analyse de la texture consiste à déterminer les différentes signatures texturales qui permettent de mieux caractériser une image. Cette analyse regroupe un ensemble de techniques mathématiques permettant de quantifier les différents niveaux de gris présents dans une image en termes d'intensité et leur distribution.

La diversité des images ainsi que l'absence d'une définition précise et formelle de la texture ont conduit à l'émergence de plusieurs méthodes d'analyse de la texture ([D'hondt 2006](#)). Le choix d'une méthode est fortement lié à la nature de la texture à discriminer et à l'application visée. Les différentes méthodes proposées dans la littérature qui traitent de l'analyse de la texture, peuvent être classées essentiellement en trois principales approches ([Diop. 2007](#)) : l'approche spatio-fréquentielle, l'approche déterministe (ou structurelle) et l'approche stochastique (ou statistique) sur laquelle sont basées les méthodes que nous avons élaborées.

2.2.1. Approche spatio-fréquentielle

Comme les textures sont des signaux quasi périodiques ayant une énergie fréquentielle localisée, cette approche est donc bien adaptée aux signaux quasi périodiques. Les représentations préservent à la fois les informations globales et locales. Les méthodes les plus utilisées et basées sur cette approche sont ([Matsuyama 1983](#) ; [Buf 1989](#) ; [Mallat 1989](#) ; [Kpalma 1992](#)) :

- ✓ la transformée de Fourier, sans doute la plus connue;
- ✓ les filtres de Gabor considérés comme des filtres précurseurs dans le domaine des méthodes de filtrage spatio-fréquentiel;
- ✓ la transformation en ondelettes.

2.2.2. Approche structurelle

Ce type d'approche est bien adapté aux macrotextures. Les images étudiées contiennent des textures constituées de motifs élémentaires qui se répètent quasi régulièrement dans différentes directions de l'espace. Ces méthodes sont basées sur deux étapes principales :

- la première consiste donc à rechercher et à extraire ces primitives de texture,
- la deuxième consiste à les décrire, puis, à déterminer des règles qui conditionnent leur position.

Pour retrouver le placement des primitives des textures initialement extraites, afin d'en déduire une règle de placement, ces méthodes font souvent appel à des techniques d'autocorrélation ([Haralick 1979](#); [Beil 1999](#) ; [Cocquerez et Philipp 1995](#)).

Les approches structurelles classiques pour lesquelles on cherche à détecter et caractériser des primitives, puis, à trouver des règles de placement, sont basées sur un ensemble de méthodes qu'on peut regrouper en deux principales stratégies qui s'appuient principalement sur le traitement du signal, la topologie et la géométrie : méthodes «bottomup» ou inversement méthodes « top-down ».

2.2.3. Approche statistique

L'approche statistique utilise donc le domaine spatial en prenant en compte l'aspect statistique de la texture dans les procédures d'analyse, puisqu'on considère que la texture a un comportement aléatoire et ne possède ni des contours forts ni de motif de base isolable. Elle consiste alors à évaluer, comme information texturale, les paramètres statistiques d'une région ou d'un certain voisinage autour d'un pixel.

2.2.3.1. Analyse basée sur l'extraction de paramètres statistiques

L'estimation de ces paramètres peut alors se faire sur une réalisation unique du processus qui est l'image de texture. Les attributs statistiques sont alors des estimations de moments statistiques ou de densités de probabilité. Les plus souvent utilisés:

- les attributs du premier ordre basés sur l'histogramme des intensités ;
- les attributs du second ordre (matrices de cooccurrences) 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.
- Matrices longueurs de plages.

Plusieurs travaux traitant des images de télédétection ont été effectués en utilisant ces différents paramètres ([Akono et al 2003](#) ; [Ameur et al 2001](#) ; [Ameur 2005](#))

2.2.3.2. Analyse basée sur basées sur la modélisation spatiale

Plusieurs études ont montré que l'œil ne prend pas en compte les dépendances qui existent entre des points éloignés. La caractérisation se fait donc à un niveau très local, ce qui explique l'importance de la notion de voisinage dans l'analyse de texture. En se basant sur une description des propriétés locales des textures, cette approche est ainsi adaptée aux microtextures dans lesquelles les relations de placement se situent à faible échelle. Ceci met en évidence l'importance de la notion de voisinage dans la compréhension du phénomène de texture qui est à la fois spatiale et statistique puisqu'elle met en place des relations de regroupements d'éléments de base de la texture. Cette approche est donc basée sur la modélisation spatiale des textures pour construire des attributs en fonction de la répartition spatiale des pixels dans l'image .Les principaux modèles sont :

- Les modèles autorégressifs multi-spectraux.
- Les motifs locaux binaires (LBP)
- Les modèles Markoviens multi-spectraux.

2.3. Méthodes de classification des images multispectrales

Le problème général de classification des images multispectrales est de ranger des individus (pixels) caractérisés par des variables (canaux spectraux) dans des classes définies par la nomenclature. Plusieurs méthodes de classifications classiques sont largement utilisées en télédétection ([McDonald et al. 2003](#) ; [Huang et al. 2004](#) ; [Bertolino et Montanvert 1996](#)), 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) ou non linéaires telles que les SVM (Support Vector Machine), les réseaux de neurones multicouches(MLP) et les champs de Markov (MLP).

Le choix d'une méthode par rapport à une autre dépend de la structure des données, mais généralement, c'est l'approche statistique qui permet d'atteindre un taux d'erreur minimal.

L'objectif des sections suivantes n'est pas de réaliser une présentation exhaustive des méthodes appartenant à chacune des catégories évoquées ci-dessus, mais de présenter les approches qui ont suscité le plus grand nombre de travaux sur les images multispectrales et plus particulièrement les réseaux de neurones multicouches et les champs de Markov sur lesquels sont basées les méthodes que nous avons élaborées.

2.3.1. Classification par minimisation de distance

Considérées généralement comme techniques non supervisées ne requérant pas de phase d'apprentissage, les méthodes basées sur la minimisation de distance cherchent toujours à affecter chaque pixel, ou un groupe de pixels si l'on travaille dans une fenêtre d'analyse centrée sur le pixel courant, à la classe la plus proche. La notion de proximité est liée à la distance considérée. Elles ont l'avantage d'être simples à mettre en œuvre et de vitesse de convergence relativement élevée. Plusieurs outils tels que les K plus proches voisins, K-means et Fuzzy-C-means sont souvent utilisés pour effectuer ce type de classification.

2.3.1.1. Classification par la méthode des K plus proches voisins (k-ppv)

Connue aussi sous le nom de k-NN (k nearest neighbours), c'est une méthode de classification dont le principe est d'affecter un pixel 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 essentiellement du choix de la valeur de k . Plusieurs algorithmes de classification de données de télédétection par les k -NN ont été développés dans la littérature (Nuzillard et Lazar 2007 ; Voisine 2002).

2.3.1.2. Méthode des K-means

C'est la méthode du clustering la plus connue et la plus utilisée car elle a l'avantage d'être facile à mettre en œuvre. C'est une méthode de classification qui prend le centre de gravité de chaque classe comme représentant de cette dernière (Theiler et Gisler 1997 ; Arthur et Vassilvitskii ,2007). A chaque nouvelle affectation d'un élément à une classe, les centres de classes sont recalculés (Moghrani 2007).

L'objectif de cette méthode est de partitionner l'espace des attributs en k classes, k étant connu. A partir d'une partition initiale on améliore itérativement la partition de l'espace en minimisant la variance intraclasse. Le résultat final est conditionné par le choix du nombre de classes et la position initiale des centres de classes. Ces derniers doivent être initialement placés le plus loin possible les uns des autres de façon à optimiser l'algorithme.

2.3.1.3. Classification par Fuzzy-C-Means

Issue de l'algorithme des C-moyennes (C-means) (Gath et Geva.1989, Wang et Fei,2008), la technique Fuzzy C-Means (FCM) est une méthode de classification floue non supervisée (Bezdek 1981) qui introduit la notion d'ensemble flou dans la définition des classes. Toutes ces classes sont caractérisées par leur centre de gravité et chaque point dans l'ensemble des données doit appartenir à chaque classe avec un certain degré. Comme les autres méthodes de classification non supervisées, cette approche est basée d'une part, sur un critère de minimisation de distance intra-classes et d'autre part, sur un critère de maximisation de distance inter-classes en fixant un degré d'appartenance de chaque pixel à chaque classe. Cette approche permet la génération des différentes classes en utilisant un processus itératif de minimisation une fonction objective, mais nécessite la connaissance à priori du nombre de clusters. Ainsi, on obtient donc une partition floue de l'image, qui donne pour chaque pixel un degré d'appartenance, dont la valeur est comprise entre 0 et 1, à chaque classe. Un pixel est associé à une classe pour laquelle le degré d'appartenance est le plus élevé.

Aussi, plusieurs approches basées sur l'algorithme des C-moyennes floues qui prennent en compte la contrainte spatiale ont été proposées dans la littérature. Parmi ces méthodes on peut citer les plus récentes, notamment celles développées par ([Bandyopadhyay 2005](#) ; [Chuang et al. 2006](#) ; [Wang et Fei, 2008](#) ; [Ahmed et al 1999](#)).

2.3.1.4. Classification par la technique ISODATA

Cette méthode qui veut dire « Iterative Self-Organizing Data Analysis Technics » proposée par ([Ball et Hall 1965](#)) est une variante de l'algorithme des K-means. Elle autorise la fusion entre points de nuages proches, la division d'un nuage à variance élevée et la suppression de nuage de petite taille au cours des itérations. L'utilisateur doit aussi spécifier ces paramètres:

- le nombre minimum de membres dans un segment (n_{min}). Un segment est donc supprimé et ses membres sont affectés s'il contient moins de membres que le minimum spécifié,
- l'écart type maximum (σ_{max}). Un segment est divisé en deux régions lorsque son écart type dépasse le maximum spécifié, et que le nombre de membres est deux fois supérieur au minimum de membres spécifiés dans une classe,
- la distance minimum entre les segments (d_{min}). Des segments sont fusionnés s'ils ont une distance pondérée inférieure à cette valeur spécifiée.

2.3.2. Classification par la méthode des hypercubes

Appelée aussi méthode du parallélépipède, cette méthode supervisée qui est basée sur une logique booléenne utilise des données d'entraînement dans « d » bandes spectrales pour effectuer la classification. Ainsi, pour chaque classe λ , un vecteur $\mu_\lambda = (\mu_{\lambda_1}, \dots, \mu_{\lambda_d})$ où μ_{λ_k} représente le niveau de gris moyen des pixels de la classe λ dans la bande k, est calculé.

En fixant un seuil égal à σ_{λ_k} qui représente l'écart type des données d'entraînement de la classe λ dans la bande k, l'algorithme du parallélépipède affecte un pixel de vecteur de mesures $X_\lambda = (x_{ij_1}, \dots, x_{ij_d})$ à la classe λ , si et seulement si la condition suivante est vérifiée:

$$\mu_{\lambda_k} - \sigma_{\lambda_k} < x_{ij_k} < \mu_{\lambda_k} + \sigma_{\lambda_k}, \forall k \in [1 \dots d] \quad (2.1)$$

Où : $k = \{1..d\}$ représente le nombre de bandes

x_{ij_k} est la valeur radiométrique du pixel (i,j) dans la bande k.

Lorsque les frontières de décision inférieure (L) et supérieure (H) sont définies respectivement par $L_{\lambda_k} = \mu_{\lambda_k} - \sigma_{\lambda_k}$ et $H_{\lambda_k} = \mu_{\lambda_k} + \sigma_{\lambda_k}$, la règle de décision du parallélépipède devient donc :

$$L_{\lambda_k} < x_{ijk} < H_{\lambda_k}, \forall k \in [1 \ d] \quad (2.2)$$

Ainsi, ces règles de décision permettent de former un parallélépipède multidimensionnel dans l'espace des caractéristiques. Un pixel est donc affecté à une classe donnée lorsque sa valeur est comprise entre la borne inférieure (L) et la borne supérieure (H) pour les « d » bandes évaluées pour cette classe. Autrement, il est affecté à une catégorie non classée. La figure suivante illustre le principe de cette méthode dans le cas à deux dimensions :




Figure 3.2: Méthode parallélépipédique dans un cas bidimensionnel

Une meilleure connaissance des objets à classer et par conséquent, un bon choix des aires pour être les plus représentatifs possibles de la dynamique spectrale de chacun d'eux, sont exigés pour utiliser cette méthode.

Comme toute autre méthode de classification, cette technique présente certains inconvénients tels que :

- ✓ la présence de certains pixels non classés ;
- ✓ l'entraînement des confusions lorsque les signatures de certaines classes spectrales se chevauchent (problème de la superposition des boîtes).

2.3.3. Machines à Support Vecteurs (SVM)

Connus aussi sous le nom de « séparateurs à vaste marge », les SVM représentent un ensemble de techniques d'apprentissage supervisé spécialisé dans le traitement des données de hautes dimensions ([Vapnik 1998](#)). Elles sont utilisées pour résoudre des problèmes de discrimination et de régression. Cette approche est basée particulièrement sur des propriétés géométriques ou frontières des ensembles à discriminer et non pas sur leurs propriétés statistiques. En plus de leur utilisation dans plusieurs domaines tels la reconnaissance de forme, l'imagerie médicale..., les SVM sont aussi souvent utilisés avec succès dans le traitement des images multispectrales. Dans certains travaux les relations inter-pixels ne sont pas prises en considération et seule l'information spectrale est utilisée ([Karimi et al. 2006](#) ; [Melgani et Bruzzone 2004](#) ; [Roli et Fumera 2001](#) ; [Gualtieri et Chettri 2000](#)).




Figure 3.3 Représentation de l'astuce du noyau (Trick Kernel)

D'autres auteurs dont Mercier, Camps-Valls ou encore Fauvel, ont proposé d'introduire une contrainte spatiale ou une information contextuelle dans les approches SVM par l'intermédiaire de certaines fonctions appelées « fonctions noyaux » ([Mercier et al. 2003](#)), ([Camps-Valls et al. 2006](#)), ([Fauvel, 2007](#), [Fauvel et al., 2007](#)). Ce qui a permis de donner des résultats très encourageants.

2.3.4. Classification par 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 ([Pappas,1992](#) ; [Vemuri et al,1995](#) ; [Ashton and Parker ,1995](#)).

2.3.5. Classification par les réseaux de neurones

Les réseaux de neurones artificiels sont des modèles statistiques inspirés de l'observation des vrais neurones biologiques et basés sur le principe de l'apprentissage par l'expérience (Rosenblatt 1958 ; Haykin 1994). Un réseau de neurones est composé d'un ensemble d'éléments de calcul simple appelés « neurones », connectés les uns aux autres par une valeur poids appelée « synapse ». Durant la phase d'apprentissage, ce réseau cherche toujours à apprendre la relation statistique existante entre les données de l'entrée et celles de la sortie et détermine les poids à attribuer à chaque connexion entre les neurones pour approximer correctement cette relation.

Contrairement aux méthodes traditionnelles, le réseau neuronal ne nécessite ni la compréhension détaillée de la physique du problème, ni la conception étape par étape d'un modèle qui permet de rendre compte de ces phénomènes physiques.

Initialement, ces systèmes étaient utilisés pour résoudre des problèmes de classification et de régression. Les premiers modèles de réseaux neuronaux dont la gamme d'application était restreinte, comportaient de nombreuses limitations mathématiques (Minsky et Papert 1969). Ces applications n'ont pu se généraliser qu'avec l'apparition d'algorithmes plus complexes et plus particulièrement les "perceptrons multicouches" (multi-layer perceptron) qui, théoriquement, peuvent approximer n'importe quelle fonction (Hornik et al. 1989 ; Kramer et Sangiovanni-Vincentelli 1989) et qui permettent principalement de résoudre des problèmes non-linéaires tels que ceux rencontrés dans le domaine des sciences atmosphériques.

Un réseau de neurones se distingue par les trois caractéristiques principales suivantes:

- L'architecture du réseau qui caractérise un chemin particulier par lequel les éléments du réseau sont connectés et qui définit la direction de propagation des informations.
- La fonction d'activation des neurones qui dicte leur comportement.
- L'algorithme d'apprentissage du réseau.

L'utilisation des méthodes basées sur les réseaux de neurones passe par les trois principales étapes suivantes :

- **La phase de construction de la base d'apprentissage** : doit être la plus représentative possible permettant d'obtenir des paires entrées-sorties. Cette base repose donc sur des couples de cibles (Entrées, Sorties) qui seront appris par les réseaux.

- **La phase d'apprentissage du réseau** : nécessite un ensemble de données pertinentes afin d'ajuster les différents coefficients de telle sorte à ce que les entrées et les sorties du réseau soient cohérentes par rapport à la base d'apprentissage et cela dans le but d'obtenir une classification fiable.
- **La phase de généralisation** : dont le principe est l'évaluation des performances du réseau avec d'autres données de même type mais qui ne sont surtout pas utilisées pendant la phase d'apprentissage.

Les réseaux de neurones ont l'avantage de posséder des fonctionnalités très utiles dans plusieurs domaines et particulièrement l'analyse d'image. Les premières applications de ces réseaux en physique de l'atmosphère ont porté essentiellement sur la classification des différents types de nuages. Plusieurs chercheurs tels que Lee et al. (1990) qui sont les premiers à adopter cette approche dans leurs travaux de classification, suivies de Welch et al. (1992) puis Bankert (1994) et Bankert et Aha (1996).

Par la suite, les précipitations ont également bénéficiées de nombreuses études qui font appel aux réseaux de neurones. Ainsi une méthode basée sur les températures de brillance et les taux de pluie en sortie du réseau a été développée par Tsindikis et al. (1997). A l'échelle régionale, d'autres approches utilisant un autre type de données telles les données radar et de pluviomètres (Matsoukas et al. 1999), ou la combinaison des données relatives à la pluie du radar et de l'imagerie multispectrale GOES (Bellerby et al. 2000) ont aussi été développées. Dans cette dernière étude, une co-localisation des informations statistiques avec les mesures de précipitations a été effectuée afin d'introduire une information sur la texture du nuage. Pour localiser et identifier les précipitations, Berges et Chopin (2004) ont fait une combinaison entre les données Météosat, GOES et TRMM en entrée du réseau qu'ils ont conçu.

Comme il est difficile d'exprimer de façon usuelle la relation qu'on peut obtenir entre le taux de pluie au sol et les observations radar, on peut faire appel aux réseaux de neurones pour résoudre ce type de problème complexe. Cette technique a été utilisée par Li et al. (2003) pour retrouver les taux de pluie de surface en prenant les données radar comme entrée du réseau et les mesures du taux de pluie comme sortie cible du réseau ainsi conçu.

Enfin, d'autres chercheurs ont utilisé les réflectances multi-spectrales issues des nuages comme entrées des réseaux de neurones. Parmi ces travaux, on peut citer ceux de Faure et al. (2001), Cornet (2003) qui ont marqué le début des restitutions de paramètres dérivés de l'IR/VIS

comme l'épaisseur optique et le rayon effectif ou encore ceux de Feidas, H., Giannakos, A ([2011 et 2012](#)) pour effectuer une identification et la classification des précipitations en deux classes : stratiformes et convectives.

2.3.6. Classification 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 traitement d'images. 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. Aussi, l'image qui est représentée par un champ de Markov nécessite le recours à des algorithmes itératifs tels que le recuit simulé et l'ICM pour estimer la loi du champ.

Plusieurs approches de classification des images de télédétection par champs de Markov ont été développées ces dernières années. On peut citer les travaux de Prony ([Prony et al. 2000](#)) dans le cadre régularisation d'une classification par maximum de vraisemblance d'images multispectrales de zone rurale et périurbaine et les travaux de Rellier ([Rellier, 2002](#)) dans le cadre de la classification d'images multispectrales texturées de zones urbaines. Dans la méthode de Prony, la construction du champ Markovien est basée sur le modèle de Potts et la configuration optimale permettant de minimiser l'énergie ainsi définie est obtenu par l'algorithme ICM puis de recuit simulé. Par contre, la méthode de Rellier est basée sur une modélisation de la texture par un modèle markovien Gaussien vectoriel appelé modèle champ de Markov Gaussien Multivarié ou MGMRF (en anglais Multivariate Gaussian Markov Random Field) tel que proposé initialement par Hazel ([Hazel, 2000](#)). Les données vectorielles constituent les observations aux différentes longueurs d'onde d'un même site. L'application du modèle de texture ainsi construit sur des images réelles AVIRIS permet d'obtenir des résultats prometteurs.

D'autres travaux qui s'intéressent à la segmentation et à la classification des images météorologiques ([Li 1995](#) ; [Huang et al. 2008](#) ; [Gong et Shu, 2007](#) ; [Smartt et Tyo 2006](#) ; [Ameur, 2000](#)) ont été effectués ces dernières années. La plupart de ces travaux ont porté essentiellement sur l'identification et la classification des différents paramètres météorologiques pouvant être extraits à partir d'images collectées par des satellites météorologiques. Ameur a

développé un modèle Markovien Multi échelle (MSMRF) associé à l'estimateur (SMAP) (Ameur,2000). Ce modèle est appliqué aux images météorologiques Météosat et a donné des résultats satisfaisants.

2.7. Dscussion

Dans ce chapitre, nous avons décrit les principales méthodes d'analyse et de classification des images multispectrales. La classification non supervisée ou automatique est utilisée, 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.

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, SVM, champs de Markov, 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.

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.

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 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.

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.

Les méthodes basées sur les champs de Markov malgré qu'elles présentent l'inconvénient de la difficulté d'implémentation et de la lourdeur algorithmique, elles jouent un rôle prépondérant en analyse d'image en exploitant la dimension spatiale (Information contextuelle). Elles permettent souvent de tracer avec une bonne précision les contours d'une zone malgré l'hétérogénéité spectrale des pixels qui la composent.

Les champs de Markov ont largement contribué avec succès à la classification des différents nuages selon leur type ou en fonction de leur altitude. C'est cette approche que nous allons utiliser pour la classification des images multispectrales MSG afin d'identifier les différents nuages d'eau que nous allons, par la suite, séparer selon leur contenu en eau en utilisant une autre méthode basée sur les réseaux de neurones multicouches et qui est décrite dans le dernier chapitre.

CHAPITRE 3

CLASSIFICATION DES IMAGES MSG PAR UNE APPROCHE MARKOVIENNE MULTISPECTRALE

3.1. Préambule

L'objectif principal de la classification est de partitionner une image donnée en un ensemble de classes homogènes, chacune porteuse d'une information élémentaire. Durant ces dernières décennies, plusieurs méthodes de classification ont été développées et utilisées dans diverses disciplines telle que la météorologie ([Arkin et Meisner 1987](#); [Anagnostou et Kummerow 1997](#); [Ba et Gruber 2001](#) ; [Smartt et Tyo 2006](#); [Gong et Shu, 2007](#); [Huang et al. 2008](#)).

Les récents progrès technologiques enregistrés dans ce domaine, ont permis l'émergence de nouveaux capteurs qui délivrent des images ayant une grande résolution, à la fois, temporelle, spatiale et spectrale. Les images multispectrales MSG sont caractérisées par une grande richesse d'information. Il est donc nécessaire de développer de nouvelles méthodes de classification exploitant cette information afin de détecter les différentes régions qui la constituent.

Dans ce chapitre, nous allons présenter une nouvelle méthode de classification multispectrale basée sur une modélisation par champs de Markov qui sont efficacement utilisés dans ce type de traitement. Elle est intéressante du fait qu'elle permet d'introduire des interactions à l'échelle du voisinage qui constitue une notion de base en imagerie. Cette méthode notée (VMMRF) utilise une stratégie vectorielle permettant de prendre en considération les interactions présentes entre les différentes composantes spectrales. Elle sera appliquée à des images MSG. La description de cette méthode, les résultats obtenus ainsi que leur interprétation seront présentés dans les sections suivantes.

3.2. Description de la méthode

Dans le cadre d'une classification des images multispectrales, trois stratégies peuvent généralement être envisagées : l'approche scalaire, l'approche marginale et l'approche vectorielle. Dans la stratégie scalaire, une combinaison des différentes composantes spectrales en une seule composante doit être effectuée, et l'image résultante représente l'image objet de la classification. La stratégie marginale consiste en une classification individuelle de chaque composante spectrale suivie d'une combinaison entre les différents résultats obtenus. La stratégie vectorielle utilise l'information vectorielle représentant l'intensité du pixel dans chaque bande spectrale afin d'effectuer une classification directe sur l'image multispectrale.

La stratégie vectorielle présente l'inconvénient d'être très complexe à mettre en œuvre et s'avère très lente et nécessite beaucoup de temps traitement par rapport aux deux autres approches. Cependant, elle possède un avantage considérable qui consiste en la prise en considération des interactions présentes entre les différentes composantes spectrales de l'image contrairement aux deux autres approches.

La méthode que nous avons développée est donc basée sur une modélisation vectorielle markovienne et permet de séparer les pixels de l'image en différentes classes en se basant à la fois sur leurs relations de voisinage et leurs intensités dans différents canaux spectraux.

Dans cette partie du chapitre, nous allons exposer le principe de classification markovienne d'images multispectrales utilisant l'estimateur du maximum *à posteriori* (MAP) mis en œuvre par un algorithme de relaxation déterministe. Elle traite, d'une part, la modélisation du champ d'observations utilisant le modèle de distribution de probabilité conditionnelle et, d'autre part, la modélisation markovienne du champ des classes utilisant la distribution de probabilité *à priori*.

3.2.1. Principe de la classification markovienne d'images multispectrales

L'image à traiter est représentée par une grille S rectangulaire bidimensionnelle de taille $m \times n$. Chaque site (pixel) s de la grille peut être désigné :

- Soit par ses coordonnées : $S = \{(i, j), 0 \leq i \leq m-1, 0 \leq j \leq n-1\}$
- Soit par son numéro d'ordre : $S = \{s_1, s_2, \dots, s_M\}$, où : $M = n \times m$ est le cardinal de S .

Cette image est caractérisée par les valeurs de niveau de gris quantifiées par un entier variant dans un intervalle fixé (généralement $[0, 255]$).

Le principe de la classification des images est décrit de la façon suivante :

Soit $X = (X_1, \dots, X_N)$ le champ des classes et $F = (F_1, F_2, \dots, F_N)$ appelé champ des observations. Pour chaque site $s \in (1, 2, \dots, N)$, ce champ prend sa valeur dans ensemble des classes $\Omega = (\omega_1, \omega_2, \dots, \omega_k)$, k étant le nombre de classes.

L'image des classes n'est pas directement accessible. Il s'agit alors, à partir d'une réalisation " f " d'un champ aléatoire F , d'attribuer une estimation " $\hat{\omega}$ ".

Cette classification utilise le critère du maximum de probabilité à posteriori (MAP) $P(X = \omega / Y = f)$. Cette approche est dite bayésienne et elle est motivée par le désir d'obtenir une classification qui tienne compte de l'information à priori dans les données d'image.

3.2.1.1. Estimation Bayésienne

La théorie statistique bayésienne est d'une importance fondamentale dans tout problème d'estimation ou de décision. Elle est particulièrement bien adaptée aux problèmes d'estimation pour lesquels l'à priori P_X , traduisant les propriétés pertinentes de la classe des solutions recherchées, et la fonction de vraisemblance $P_{F/X}$, modélisant le processus conduisant aux observations, sont connus.

Si on note la solution recherchée (exacte) par $\omega^r \in E$, alors son estimée $\hat{\omega} \in E$, optimale au sens bayésien, est celle qui minimise le risque de Bayes, défini comme étant l'espérance conditionnelle aux observations d'une fonction de coût. En d'autres termes :

$$\hat{\omega} = \arg \min_x \int C(\omega^r, \omega) P_{X/Y}(\omega^r / f) d\omega^r \quad (3.1)$$

L'estimation de la solution recherchée nécessite outre la spécification de la fonction de coût C , la connaissance de la distribution de probabilité à posteriori donnée par cette équation :

$$P_{X/Y}(\omega / f) = \frac{P_{Y/X}(f / \omega) P_X(\omega)}{P_Y(f)} \propto P_{Y/X}(f / \omega) P_X(\omega). \quad (3.2)$$

La fonction de coût C , mesurant l'écart entre la solution recherchée ω^r (vraie) et son estimée $\hat{\omega}$, est généralement laissée à l'appréciation de l'utilisateur. Cependant une fonction, souvent utilisée, définit l'estimateur le plus répandu dans la littérature que nous détaillerons ci-dessous : l'estimateur au sens du maximum à posteriori (MAP). D'autres estimateurs existent, notamment l'estimateur du mode des marginales à posteriori (MMP), l'estimateur du Champ Moyen (MF), l'estimateur de la moyenne à posteriori (MP) (Kato et al, 1993). Une autre version de l'estimateur MAP, le MAP séquentiel (SMAP), a été proposé par Bouman et Shapiro pour la compression d'images (Bouman and Shapiro, 1994). Ce modèle a été appliqué dans le cadre de la classification des images satellitaires météorologiques (Ameur, 2000).

3.2.1.2. Estimateur au sens du maximum a posteriori (MAP)

L'estimateur MAP est associé à la fonction de coût $C_{MAP}(\omega^r, \omega) = 1 - \delta(\omega^r - \omega)$, où δ représente le symbole de Kronecker. Cette fonction de coût pénalise de la même façon toutes les configurations de ω , différentes de la solution recherchée ω^r . Autrement dit, elle pénalise de façon identique une erreur sur un site et une erreur sur plusieurs sites.

D'après (3.1) et (3.2):

$$\hat{\omega}_{MAP} = \arg \max_x P_{X/Y}(X = \omega / F = f) \quad (3.3)$$

$P(X = \omega / F = f)$ est la probabilité conditionnelle de la classe " ω " sachant l'observation " f ".

En utilisant la règle de Bayes, la probabilité à posteriori est exprimée comme:

$$P(X = \omega / F = f) = \frac{P(F = f / X = \omega)P_X(X = \omega)}{P_Y(F = f)} \quad (3.4)$$

$P(F = f / X = \omega)$ représente la distribution de probabilité conditionnelle de l'observation " f " sachant la classe " ω ".

$P(X = \omega)$ est la distribution de la probabilité de la classe " ω " (probabilité à priori) qui peut être modélisée en imposant une contrainte de connectivité spatiale sur la classification.

$P(F = f)$ est la distribution de probabilité que l'observation " f " survienne.

En supposant que $P(F = f)$ est la même pour toutes les observations " f ", maximiser $P(X / F)$ revient à maximiser $P(F / X) P(X)$:

$$\begin{aligned} P(X = \omega / F = f) &= \arg \max_x P_{F/X}(F = f / X = \omega) P_X(X = \omega) \\ &= \arg \min_x \{-\ln P_{F/X}(f / \omega) - \ln P_X(\omega)\} \end{aligned} \quad (3.5)$$

L'estimation au sens du MAP revient donc à maximiser la densité de probabilité *à posteriori*, équivalent à la minimisation d'une fonction d'énergie reposant sur :

- ✓ la vraisemblance de la solution par rapport aux observations.
- ✓ la spécification d'un *à priori* sur la solution recherchée.

La recherche du minimum global est souvent faite par des algorithmes coûteux en terme de temps de calcul tels que les algorithmes stochastiques de type recuit (Kato et al, 1993). Néanmoins, des solutions approchées peuvent être obtenues par des algorithmes déterministes comme l'ICM (Besag, 1986) ou le HCF (Chou and Brown, 1990). Dans le cas des problèmes de la classification, la configuration MAP-ICM est la plus répandue (Bouman and Liu, 1991 ; Pappas, 1992 ; Kervrann and Heitz, 1993 ; Ashton and Parker, 1995 ; Collet et al, 1995 ; Collet et al, 1996 ; Rouquet and Bonton, 1997 ; Boukerroui et al, 1998 ; Mignotte, 1998).

Pour obtenir la classe la plus probable " $\hat{\omega}$ " de l'équation (3.3) en utilisant la maximisation de la probabilité *à posteriori*, il est donc nécessaire de réaliser ces deux étapes :

La première consiste à modéliser le champ des observations et le champ des classes, c'est-à-dire trouver le modèle statistique de $P(F = f / X = \omega)$ et le modèle de $P(X = \omega)$. Dans notre travail, la modélisation des observations est basée sur le modèle gaussien (Derin and Elliott, 1987), alors que la modélisation des classes est basée sur un champ markovien permettant de prendre en compte les dépendances statistiques spatiales entre sites adjacents.

La deuxième est l'optimisation de la probabilité *à posteriori* qui peut être effectuée en utilisant soit une approche de type stochastique (recuit simulé (Kato et al, 1993)), soit une approche de type déterministe (par exemple l'algorithme ICM (Bouman and Liu, 1991)). C'est cette deuxième approche que nous avons utilisé.

3.2.2. Modèle Markovien de classification d'images multispectrales

Dans cette partie nous présentons un modèle Markovien de classification d'images. Nous cherchons l'étiquetage $\hat{\omega}$ qui maximise la probabilité à posteriori $P(\omega/F)$. C'est à dire l'estimateur MAP du champ des étiquettes :

$$P(\omega / F) = \frac{1}{P(F)} P(F / \omega) P(\omega) \quad (3.6)$$

$P(F)$ ne dépend pas de l'étiquetage et nous supposons que :

$$P(F / \omega) = \prod_{s \in S} P(f_s / \omega_s) \quad (3.7)$$

L'étiquetage recherché sera donné par :

$$\hat{\omega} = \arg \max_{\omega \in \Omega} \prod_{s \in S} P(f_s / \omega_s) \prod_{C \in C'} \exp(-V_C(\omega_C)) \quad (3.8)$$

3.2.2.1. Modélisation du champ des observations

En absence d'informations sur la nature de la distribution des observations, la densité de probabilité conditionnelle $P(f / \omega)$ de l'équation (3.6) peut être modélisée par une loi gaussienne (Kato et al, 1993). La loi gaussienne multidimensionnelle est la mieux adaptée dans le cas des images multispectrales.

La probabilité $P(f_s / \omega_s)$ (avec f_s désigne la valeur observée du site "s") peut donc être modélisée sous la forme suivante [Derin et Elliott, 1987] :

$$P(f_s / \omega_s) = \frac{1}{(2\pi|\sigma_\omega|)^{B/2}} \exp\left(-\frac{1}{2}(a_s - \mu_s)^T \sigma_\omega^{-1}(a_s - \mu_s)\right) \quad (3.9)$$

Où :

B : est le nombre de canaux spectraux utilisés.

f_s : est le vecteur les valeurs du site s dans différents canaux de l'image.

μ_s : est le vecteur des moyennes de la classe ω .

σ_k : est la matrice des variances covariances de la classe ω entre les différentes composantes

La détermination de cette probabilité dépend de l'ensemble des moyennes et des matrices variances covariances des classes. Cet ensemble forme le vecteur des paramètres à

estimer.

En supposant que $P(f_s / \omega_s)$ soit strictement supérieure à zéro, on pose :

$$E_1(f / \omega) = -\ln P(f_s / \omega_s) \quad (3.10)$$

E_1 sera considéré comme une composante de l'énergie globale qui sera utilisée pour déterminer la classe la plus probable.

Selon Rignot et Chellapa (1991), l'utilisation de l'expression exacte de la probabilité conditionnelle n'améliore pas d'une façon significative les résultats, en regard de la complexité et du temps de calcul supplémentaire. Par ailleurs, l'apport de l'information contextuelle est introduit tout naturellement dans le modèle markovien du champ des classes.

3.2.2.2. Modélisation markovienne du champ des classes

Généralement, dans les méthodes de classification conventionnelles telles que la méthode du maximum de vraisemblance, la probabilité *à priori* est supposée identique pour toutes les classes. Cela est incorrect, en ce qui concerne les objets d'une scène naturelle. De plus, le résultat final de la classification peut inclure des régions isolées à cause de la présence du bruit. Afin d'éviter ces problèmes, l'utilisation de l'information du voisinage permet de jouer un grand rôle dans la détermination des probabilités *à priori*. Il s'agit alors, d'assimiler le champ des classes à un champ markovien.

Nous supposons que chaque pixel est étroitement lié à ses voisins. Le champ de classes X est considéré comme un champ aléatoire de Markov par rapport au système de voisinage si la loi de probabilité conditionnelle de ω_s sachant (ω_T) , (avec $T \neq s$ et " T " est l'ensemble des pixels dans l'image), est égale à la loi de probabilité conditionnelle de ω_s , sachant ω_t ($t \in \Gamma_s$ et " t " est l'ensemble des sites formant le voisinage). (Voir équation (B.3)). Cela signifie que la connaissance d'un voisinage local Γ_s , du pixel " s " est suffisante pour calculer la probabilité *en* chaque pixel " s ".

Le champ de Markov permet de préciser la dépendance aléatoire entre les pixels voisins : qu'on observe l'image entière (sauf le pixel " s ") ou le voisinage Γ_s (sauf le pixel " s "), on obtient la même densité de probabilité conditionnelle (Hillion et al., 1989). La supposition

que toutes les configurations du champ X ont une probabilité non nulle de se produire permet de considérer que le champ X des classes a une distribution de Gibbs relative à (S, Γ_s) . La distribution de Gibbs permet d'imposer la contrainte de connectivité sur le champ de classes. Cette distribution est une mesure de probabilité $P(\omega)$ sur l'ensemble des classes, elle est donnée par l'équation (B.4).

Le théorème d'Hammersley-Clifford ([Besag, 1974](#)) permet d'exprimer la fonction d'énergie E_2 en fonction des valeurs de " ω " sur "les cliques" du voisinage (Γ_s) utilisé ([Geman and Geman, 1984](#)). La fonction d'énergie $E_2(\omega)$ est obtenue sous la forme d'une somme de potentiels locaux $V_c(\omega)$ sur les cliques c de C , de la façon suivante:

$$E_2(\omega) = \sum_{c \in C} V_c(\omega) \quad (3.11)$$

Où : V_c est la fonction de potentiel associée à chaque clique c et C est l'ensemble de cliques correspondant au voisinage choisi.

La fonction de potentiel permet de caractériser la différence ou la ressemblance entre les pixels de chaque clique.

En utilisant un système de voisinage des quatre ou huit plus proches voisins et en considérant seulement les cliques à deux pixels, la fonction de potentiel V_C est choisie de la façon suivante ([Pappas, 1992](#)) :

$V_c = -B$ si les deux pixels de la clique ont la même valeur.

$V_c = B$ si les deux pixels de la clique ont des valeurs différentes.

Où : B est un paramètre positif à estimer dont le rôle est de favoriser l'homogénéité spatiale entre pixels voisins. La valeur optimale de ce paramètre permettant d'arriver à un résultat plus précis est déterminée d'une manière expérimentale. Le choix de ce paramètre sera discuté lors de l'interprétation des résultats.

Cette fonction de potentiel impose une contrainte de connectivité spatiale sur la segmentation. L'affectation du potentiel permet de donner une probabilité élevée pour les paires de pixels ayant des étiquettes identiques et une probabilité faible pour les paires de pixels ayant des étiquettes distinctes.

L'énergie $E_2(\omega)$ de l'équation (3.11) peut être considérée comme un terme énergétique comparable à $E_1(f/\omega)$ de l'équation (3.10).

3.2.2.3. Fonction d'énergie globale

Comme nous l'avons vu dans les équations (B.4) et (3.9), $P(F/X)$ et $P(X)$ sont des fonctions exponentielles.

En supposant que:

$$E_1(f/\omega) = -\ln P(f_s/\omega_s) \quad (3.12)$$

$$E_2(\omega) = -\ln P(\omega_s) \quad (3.13)$$

l'estimateur du maximum à *posteriori* de l'équation (3.3) devient:

$$\hat{\omega} = \arg \max_{\omega \in \Omega} (\exp - (E_1(f/\omega) + E_2(\omega))) \quad (3.14)$$

Lorsque, seules, les fonctions d'énergie sont considérées, nous aurons:

$$\hat{\omega} = \arg \min_{\omega \in \Omega} (E_1(f/\omega) + E_2(\omega)) \quad (3.15)$$

Donc, la configuration de la classe la plus probable est celle qui présente une énergie globale minimale E_G , avec:

$$E_G(\omega, f) = E_1(\omega/f) + E_2(\omega) \quad (3.16)$$

Nous constatons que la fonction globale d'énergie a deux composantes : l'une utilise l'intensité des régions obtenue à partir des données observées et l'autre impose la connectivité spatiale entre les classes. Par conséquent, l'estimation de la classification ne dépend pas uniquement de l'intensité des images, mais aussi des propriétés spatiales imposées par le modèle du champ aléatoire de Markov.

Nous Venons d'expliquer les fondements mathématiques de la stratégie bayésienne et les modélisations du champ de classes et du champ d'observation. Les deux modélisations présentées ci-dessus, seront appliquées dans l'algorithme d'optimisation de maximisation de la

probabilité à posteriori.

3.2.2.4. Optimisation de la probabilité à posteriori

L'estimation au sens du MAP associée à une modélisation markovienne nous conduit toujours à un problème d'optimisation qui consiste à déterminer la classe la plus probable qui maximise la probabilité à postérieure. Ce qui revient à la minimisation d'une fonction d'énergie. Ainsi le problème d'estimation devient un problème d'optimisation difficile car la fonction d'énergie présente de nombreux minima locaux.

De ce fait, il est nécessaire de faire appel à des algorithmes itératifs pour tenter d'approcher un minimum global. Cette optimisation peut être réalisée :

- soit par des algorithmes de relaxation stochastique de type recuit ([Metropolis et al, 1953](#)), les seuls possédant des propriétés de convergence asymptotique (en un temps infini) vers un minimum global et indépendamment de la configuration initiale ;
- soit par des algorithmes déterministes ([Chou.and Brown,1990](#)) convergeant vers un minimum local qui dépend de la configuration initiale.

Bien que les algorithmes déterministes soient sous optimaux, ils sont rapides et convergent vers des solutions acceptables lorsque la configuration initiale n'est pas trop "mauvaise".

L'algorithme ICM, proposé par Besag (1986), s'avère important puisqu'il se base sur une méthode déterministe qui a la propriété de converger rapidement. Il est déterministe dans le sens où, l'examen d'un site "s" permet systématiquement d'affecter au site "s" la classe pour laquelle l'énergie est minimale.

C'est un algorithme itératif et permet de minimiser la fonction d'énergie à chaque pixel, connaissant la valeur observée du pixel et la classe courante de tous les autres pixels à l'intérieur de la fenêtre du voisinage. L'ensemble des pixels de la fenêtre du voisinage est utilisé dans le calcul de la probabilité à *priori* basée sur la loi de Gibbs.

La qualité du résultat de la classification dépend essentiellement de l'image

d'initialisation dont le choix est très important pour effectuer ce type de traitement.

L'algorithme ICM que nous avons utilisé pour minimiser la fonction d'énergie est décrit par les étapes suivantes:

- 1) L'étape d'initialisation: qui consiste à fournir à l'algorithme une image classifiée et d'estimer les paramètres de la classification initiale correspondant à la moyenne et à la variance de chaque classe.
- 2) A partir d'une configuration initiale, les étapes suivantes sont réalisées :

Pour chaque pixel :

Pour chaque classe :

- ✓ Calculer l'énergie conditionnelle $E1$ (Equation 3.12)
 - ✓ Calculer l'énergie à priori $E2$ (Equation 3.13)
 - ✓ Calculer l'énergie globale $EG = E1 + E2$ (Equation 3.16)
 - ✓ Rechercher la classe qui donne l'énergie globale minimale.
- 3) Affecter l'étiquette de cette classe au site courant.
 - 4) Vérifier si le critère d'arrêt est satisfait. Si oui, l'algorithme s'arrête, sinon on retourne à l'étape 2).

Le critère d'arrêt utilisé peut être défini de deux façons suivantes:

- soit en fixant un seuil à ne pas dépasser sur le nombre de pixels ayant changé de classe à la dernière itération qui est généralement, de l'ordre de 10 % du nombre de pixels dans la scène,
- soit en précisant, à l'avance, le nombre d'itérations qu'il faut effectuer.

3.3. Application de la méthode aux images MSG

Dans cette section, nous allons appliquer la méthode que nous avons proposée sur un ensemble d'images météorologiques MSG collectées durant le mois de novembre 2011.

3.3.1. Présentation des données

Les images que nous allons traiter sont issues du satellite météorologique MSG qui permet de couvrir en permanence la totalité de la région d'étude que nous avons choisie représentant l'Afrique du Nord, la mer Méditerranée, le Sud Ouest de l'Europe et une partie de l'océan Atlantique. Ces images nous ont été fournies par le centre de l'Office National de Météorologie (ONM) situé à Dar El Beida à Alger. Elles ont été collectées par le satellite MSG toutes les quinze minutes et enregistrées dans le centre de l'Agence Spatiale Européenne (ESA) situé dans la ville de Darmstadt en Allemagne.


Comme le principal objectif de ce travail de recherche est d'identifier les différentes composantes d'une image satellitaire et plus particulièrement les nuages, il convient donc de choisir les bons canaux qui mettent en évidence les différentes informations contenues dans cette image et faciliter son interprétation.

Parmi les douze composantes spectrales dont dispose le satellite MSG, nous avons retenu trois canaux représentant différentes propriétés physiques. Il s'agit des deux canaux visibles VIS0.6 et VIS0.8 et du canal infrarouge NIR1.6. Ils sont bien adaptés à l'identification des nuages bas, des nuages hauts et épais et des surfaces telles que les sols, les végétations, les océans et les mers. Le choix de ces canaux a été fait après avoir étudié les signatures spectrales des surfaces de scènes naturelles. Le canal VIS0.6 renseigne sur l'épaisseur optique des nuages, le canal VIS0.8 délivre une information sur l'indice de végétation, par contre le canal NIR1.6 fait une distinction entre les nuages, la neige sur les sols. Afin d'affiner le résultat de la classification et de lever certaines ambiguïtés, nous avons introduit par la suite le canal IR 10.8 comme information supplémentaire.

Les images de la figure 3.1 montrent à titre d'exemple les images correspondant à la scène du 23 novembre 2011 à 11h45 prises par ces différents canaux au-dessus de l'Afrique


du Nord. Chaque composante spectrale utilisée est représentée par une image en niveau de gris de taille 512x512 pixels et codée sur 8 bits.

Ces images ont été prises en période de mauvais temps afin de mettre en évidence une importante couverture nuageuse présente au-dessus de la mer méditerranée et au nord de l'Algérie. Leurs caractéristiques sont décrites dans le premier chapitre.



(a) Image VIS 0.6

(b) Image VIS 0.8



(c) Image IR 1.6

(d) Image IR 10.8

Figure 3.1 : Images MSG de la zone couvrant l’Afrique du Nord, la mer Méditerranée, l’Europe de l’ouest et l’Atlantique, acquises le 28 novembre 2011 à 11h45m UTC.

3.3.2. La composition colorée

Afin de faciliter l’interprétation des résultats de classification obtenus après application de notre méthode, nous avons construit une composition colorée pour identifier les différentes régions composant ces images. Cette composition illustrée par la figure 3.2 est construite en combinant les trois images prises au même instant dans trois canaux différents. Elle est obtenue en assignant respectivement les images VIS0.6, VIS0.8 et NIR1.6 aux composantes bleu, vert et rouge. C’est l’une des combinaisons, parmi les différentes combinaisons standards possibles, la plus généralement utilisée dans ce type d’applications. L’image qui en résulte est composée de sept classes identifiées par différentes couleurs.




Figure 3.2 : Résultat de la combinaison colorée (VIS0.6, VIS0.8, IR1.6) de la scène du 23 novembre 2011 prise à 11H45 UTC

Les nuages bas apparaissent en gris clair dans la composition colorée. Leur faible éclat indique qu'ils sont de basse altitude. La couleur bleue est affectée aux nuages épais de moyenne altitude générant de fortes précipitations. Elle est aussi associée à la glace et à la neige qui absorbe une partie du rayonnement IR1.6 et réfléchit mieux dans le VIS0.6 que dans le VIS0.8. Les sols humides ainsi que d'autres nuages bas et épais tels que les cumulus sont représentés avec la couleur pourpre. Les sols très humides et les montagnes des Alpes, des Pyrénées et de l'Atlas, apparaissent dans la teinte brune. Les surfaces désertiques et les régions semi arides sont représentées par la couleur saumon. Elles ont une réflectance qui augmente en allant des courtes vers les grandes longueurs d'ondes. La couleur verte décrit la végétation qui réfléchit essentiellement dans le VIS0.8. Elle couvre l'Afrique du Nord et

l'Europe du Sud. Enfin, la couleur noire est associée à l'eau couvrant l'océan Atlantique, la mer Méditerranée et les différents lacs contenus dans la zone observée. En effet, l'eau absorbe fortement le rayonnement solaire dans l'IR 1.6 et dans le VIS 0.8.

Nous remarquons que la couverture nuageuse peut être identifiée en analysant simultanément les trois images et la composition colorée correspondante. Ces images sont brouillées par des contours flous, ce qui rend difficile la séparation des différents types de nuages qui la constituent.

Il est à noter que les différents types de nuages qui apparaissent dans la composition colorée ont aussi été mis en évidence lors des observations météorologiques réalisées en Algérie le même jour.

3.3.3. Résultats et interprétation

Après application de la méthode sur ce type de données, nous avons obtenu une partition de l'image multispectrale MSG en sept classes homogènes représentant les différentes surfaces décrites ci-dessus.

Ces classes ont été identifiées en faisant une comparaison entre l'image classifiée de la figure 3.3 et la composition colorée de la figure 3.2 tout en exploitant les cartes géographiques des régions appartenant à la zone d'étude considérée.

La segmentation markovienne décrite par l'algorithme ICM nécessite des valeurs initiales des vecteurs des moyennes et des matrices des variances covariances de chaque classe. Ceux-ci sont obtenus par une classification initiale des pixels des images relativement à l'une des composantes spectrales ou à la composante I_{moy} qui correspond à la moyenne arithmétique de ces différentes composantes spectrales

La figure 3.3 montre le résultat initial de la classification des pixels de l'image I_{moy} correspondant à la moyenne arithmétique des trois composantes spectrales VIS0.6, VIS0.8 et IR1.6




Figure 3.3: Résultat initial de la classification en 7 classes de l'image I_{moy} résultat de la moyenne arithmétique des trois images VIS0.6, VIS0.8 et IR1.6 de MSG

Pour faciliter la comparaison avec la composition colorée, nous les avons représentées avec différentes couleurs (noir, rouge, vert, bleu, jaune, bleu clair et rose) afin de mettre en évidence les sept classes. Le résultat obtenu est illustré par la figure 3.4 suivante :




Figure 3.4 : Résultat initial de classification en 7 classes représentées avec différentes couleurs

Le résultat final obtenu après convergence de l'algorithme de classification rapporte les images des figures 3.5 et 3.6.

Comme le montre l'image de la figure 3.6, les classes représentant les différents types de nuages, sont représentées en bleu clair, noir et rose. Ces nuages sont de type : Stratus-Fractus, Cumulus-Stratocumulus et Altocumulus -Altostratus.

La classe en bleu clair est affectée aux nuages d'étage moyen et aussi à la neige ou la glace couvrant le sommet des montagnes dans les régions à ciel clair. Les nuages bas qui apparaissent en gris clair dans la composition colorée sont représentés par la couleur noire.




Figure 3.5: Résultat final de la classification en 7 classes en utilisant les trois images VIS0.6, VIS0.8 et IR1.6 de MSG

La classe définie par la couleur rose est assignée aux sols humides et à d'autres types de nuages bas. La classe de couleur verte est affectée à la végétation qui apparaît dans les zones couvrant l'Europe du Sud et l'Afrique du Nord. Le désert saharien ainsi que le sol s'étendant le long des chaînes de l'Atlas sont représentés respectivement par les classes de couleur jaune et rouge. La classe bleue foncée représente l'Océan Atlantique, la Mer Méditerranée, les lacs et diverses étendues d'eau.

Les observations météorologiques effectuées en Algérie par l'Office National de la Météorologie (ONM) pendant le mois de Novembre 2011 à travers le Synop publié, indique la présence, au nord de l'Algérie, de nuages d'étages bas et moyen le 23 novembre 2011. Ces

observations confirment que ces nuages sont des Stratus-Fractus, des Cumulus-Stratocumulus et des Altocumulus –Altostratus.




Figure 3.6 : Résultat final de classification en 7 classes représentées avec différentes couleurs.

Nous constatons donc, qu'il existe une correspondance entre les résultats que nous avons obtenus et ceux observés par l'ONM à la même date. En effet, les différentes zones composant une image MSG représentant les différentes surfaces qui la constituent sont identifiées distinctement par sept classes, chacune exprimant les caractéristiques texturales de la surface qu'elle représente. Néanmoins, ces résultats sont entachés par certaines ambiguïtés entre les surfaces ayant les mêmes propriétés texturales. A titre d'exemple, nous remarquons la présence de petites taches vertes et roses décrivant la végétation et le sol qui ne doivent pas

apparaître dans certaines zones telles que celles observées au bord de la classe bleu représentant la grosse perturbation atmosphérique entre l'Espagne et l'Algérie au dessus de la mer méditerranée.

Afin de corriger ou de minimiser cette erreur, nous avons introduit l'image de la figure 3.1 (d) délivrée par le canal IR 10.8, comme entrée supplémentaire dans notre algorithme de classification. Le résultat obtenu avec cette information rapporte l'image de la figure 3.7.




Figure 3.7 : Résultat final de classification en 7 classes représentées avec différentes couleurs en utilisant les quatre images VIS0.6, VIS0.8, IR1.6 et IR10.8 de MSG.

En analysant cette image, nous remarquons que l'ambiguïté précédente est moins flagrante en prenant en considération cette quatrième information spectrale. Effet les taches

évoquées précédemment n'apparaissent pas des les zones signalées. Cependant, l'introduction de ce quatrième canal a causé la perte d'information dans certaines zones. En comparant ce résultat à celui fourni par la composition colorée, nous pouvons constater par exemple la présence de la couleur bleu représentant la mer à la place de parties contenant des pixels devant être classés en couleur verte indiquant la végétation.

Afin d'avoir une impression visuelle sur les performances de notre méthode, nous avons testé la méthode Markovienne monospectrale sur chacune des trois images choisie précédemment. Cette méthode est largement utilisée dans le cadre de la classification des images satellitaires et donne souvent de bons résultats. Les résultats obtenus après application de cette technique sur les images VIS0.6, VIS0.8 et IR1.6 sont représentés respectivement par les figures 3.8, 3.9 et 3.10.

Pour une meilleure appréciation des résultats, nous allons représenter pour chaque type de données, l'image originale, le résultat initial, le résultat final de classification et l'image correspondante représentée avec des couleurs.






Figure 3.8: Résultats de la classification en 7 classes de l'image IR1.6



(a) Image initiale

(b) Initialisation



(c) Résultat de la classification

(d) Représentation colorée

Figure 3.9: Résultats de la classification en 7 classes de l'image VIS0.8 .




Figure 3.10: Résultats de la classification en 7 classes de l'image VIS0.6

En observant ces différentes images, nous remarquons une certaine confusion entre les différentes classes de l'image. Par exemple dans la figure 3.10, la végétation se trouvant à

l'ouest de la France n'apparaît pas en vert. Elle est confondue avec la mer. Aussi, les différents types de nuages et du sol, ne sont pas correctement identifiés et différenciés. C'est le cas également pour les deux autres images où nous constatons cette confusion qui existe soit entre des classes représentant le même type de surfaces telles que les nuages ou les sols, soit entre des classes correspondant aux différents types de surfaces comme les nuages et le sol, la végétation et la mer ou la végétation et le sol.

En comparant ces résultats entre eux, nous constatons que les informations obtenues à partir de ces deux images sont complémentaires. La combinaison de ces deux informations par l'intermédiaire de la méthode VMMRF où les différentes classes ont été correctement identifiées, nous permet de dire que le traitement multispectral à travers la qualité de résultats qu'il donne, est le plus performant et le mieux adapté pour la classification de ce type de données.

Rappelons que la qualité de la classification Markovienne utilisant la fonction d'énergie E dépend du choix du paramètre B . Ce dernier correspond au facteur de régularisation de l'homogénéité. La détermination de ce paramètre est effectuée à l'aide d'une étude expérimentale. Les résultats de l'étude expérimentale sur la variation de ce paramètre montrent que l'initialisation de ce paramètre à une valeur entre 0.5 et 1 peut être admise. Néanmoins, nous avons constaté que le plus faible pourcentage d'erreur de classification est obtenu lorsque la valeur de B est égale à 0, 7.

3.3.4 Evaluation de la méthode

Afin de confirmer ces différentes analyses et interprétations, nous allons évaluer d'une manière objective les performances de cette méthode à travers la qualité de sa classification. Pour cela, nous avons fait appel au critère d'uniformité intra région de Levine et Nazif (Laurent et al. 1984) donné par la formule suivante :

$$G = 1 - \frac{\sigma_w^2}{\sigma_T^2} \quad (3.17)$$

Où :

σ_w^2 est la variance intra classe et σ_T^2 est la variance totale.

$$\sigma_w^2 = \frac{1}{M} \sum_{i=1}^k \sum_{s \in \omega_i} (a_s - m_i)^2$$

$$\sigma_T^2 = \frac{1}{M} \sum_{i=1}^k (a_s - m)^2$$

$$m = \frac{1}{M} \sum_{s=1}^M (a_s)$$

$$m_i = \frac{1}{M_i} \sum_{s \in \omega_i} (a_s)$$

$$M_i = \sum_{s \in \omega_i} (1)$$

Avec : ω_i est la classe i de l'image,

k est le nombre de classes,

a_s est le niveau de gris du pixel s,

M le nombre de pixels de l'image,

M_i le nombre total des pixels de la classe C_i ,

m_i est la moyenne des niveaux de gris de la classe C_i ,

m est la moyenne totale des niveaux de gris de l'image.

Notons que la qualité de la segmentation est meilleure lorsque la valeur de ce paramètre est d'autant plus élevée.

Le tableau 3.1 montre le pourcentage (Prc) de pixels ayant changés de classes à la dernière itération ainsi que le critère d'uniformité (G) pour chaque cas de classification.

A travers les valeurs de ce tableau, nous constatons que les meilleurs résultats sont donnés par le modèle (VMMRF). En effet, les plus faibles valeurs du paramètre Prc sont enregistrées dans cette situation avec un taux de (2.4382%). De plus, ces valeurs sont confortées par celles de l'indice d'uniformité G dont la plus élevée est celle calculée dans ce cas aussi et qui est de l'ordre de (0.9811).

Notons aussi, que tous ces résultats sont calculés pour un nombre d'itérations égal à 9

itérations dans le cas multispectral et à 6 itérations dans le cas monospectral. Ces valeurs empiriques sont estimées suffisantes pour effectuer une bonne classification. Les bonnes valeurs du paramètre *Prc* calculées pour les différentes images restent largement inférieures au seuil de 10 % souvent utilisé comme critère d'arrêt par plusieurs auteurs. La valeur moyenne maximale qui est de 6.4343% est celle calculée pour l'image IR 10.8.

Image	Paramètres	Classe1	Classe2	Classe3	Classe4	Classe5	Classe6	Classe7	Moy
VIS 0.6	<i>Prc</i>	5,1464	4,2709	4,1072	3,9313	3,9129	4,0546	4,1798	4,2290
	<i>G</i>	0,9288	0,9321	0,9365	0,9262	0,9311	0,9437	0,9318	0,9329
VIS 0.8	<i>Prc</i>	4,3539	4,3313	4,3556	3,1829	4,3991	4,3979	4,1898	4,1729
	<i>G</i>	0,9498	0,9484	0,9479	0,9418	0,9482	0,9583	0,9560	0,9501
IR 1.6	<i>Prc</i>	3,7440	3,8489	3,8034	3,8869	3,9313	3,8802	3,7700	3,8378
	<i>G</i>	0,9688	0,9650	0,9589	0,9605	0,9816	0,9688	0,9732	0,9681
IR 10.8	<i>Prc</i>	7,6613	6,7709	8,7133	5,7434	4,83	6,7529	4,5686	6,4343
	<i>G</i>	0,9128	0,9351	0,9249	0,9105	0,9116	0,9388	0,9032	0,9196
VMMRF	<i>Prc</i>	2,4709	2,3879	2,3413	2,5542	2,4775	2,5700	2,2653	2,4382
	<i>G</i>	0,9879	0,9904	0,9800	0,9751	0,9802	0,9730	0,9811	0,9811

Tableau 3.1 : Paramètres calculés pour les 07 classes de chaque image

La figure 3.11 montre le résultat de la classification dans le cas à trois images avec 7 classes après 4, 6, 8 et 9 itérations. Elle montre l'image originale, la classification initiale ainsi que le résultat de la classification après chacune de ces itérations.

En observant cette figure, nous constatons qu'effectivement les résultats de la classification commencent à s'améliorer et à se stabiliser à partir de la cinquième itération. Les images obtenues apparaissent quasi semblables. Nous constatons aussi que les zones contenant des pixels isolés diminuent en augmentant le nombre d'itérations et s'éliminent d'une façon significative à partir de la huitième itération. Ceci est justifié par l'introduction de l'information spatiale et par la prise en compte des voisins de chaque pixel à classer. Ce résultat est attendu dans le cas de la classification markovienne qui est basée essentiellement sur cette notion de voisinage.

A la dixième itération, nous remarquons visuellement que l'image classifiée ne présente

quasiment aucun changement par rapport à celle obtenue à la neuvième itération.




Figure 3.11: Résultats de la classification multispectrale après différentes itérations.

Les valeurs des paramètres P_{cr} et G du modèle Markovien multispectral calculées pour différentes itérations sont données par le tableau 3.2. La figure 3.12 montre la variation de ces paramètres en fonction du nombre d'itérations.

Nous constatons qu'après la troisième itération le P_{cr} devient inférieur à 10%, continue

à diminuer en augmentant le nombre d'itérations et commence à se stabiliser à partir de la sixième itération. La stabilité est atteinte à partir de la neuvième itération.

Itération	1	2	3	4	5	6	7	8	9	10	11	12	13
Prc	15,22	12,05	9,6435	7,7217	5,6851	3,6809	3,1714	2,9624	2,4382	2,4463	2,4301	2,4426	2,4363
G	0,5567	0,6917	0,8354	0,8485	0,8694	0,8973	0,9312	0,9628	0,9811	0,9804	0,9816	0,9836	0,9824

Tableau 3.2: Valeurs des paramètres Prc et G calculées pour différentes itérations




Tableau 3.2: Variation des paramètres Prc et G en fonction du nombre des itérations

Tous ces résultats sont appréciables et concordent convenablement avec ceux illustrés par la figure 3.11.

3.4 Discussion

Dans ce chapitre, nous avons présenté une méthode qui traite le problème de la classification des images multispectrales. La méthode proposée est basée sur le principe de la modélisation Markovienne multispectrale utilisant l'estimateur du maximum à *posteriori* (MAP) mis en œuvre par un algorithme de relaxation déterministe (ICM). Nous l'avons appliqué sur des images météorologiques acquises par le satellite MSG.

Les résultats obtenus ont prouvé que cette méthode est bien adaptée à ce type de

données. Elle a correctement détecté et identifié les mers, les sols et les différents nuages tout en reproduisant d'une manière satisfaisante les contours de l'image de la scène prise le 23 novembre 2011 à 11h45.

Ces différentes classes sont obtenues par l'application d'un algorithme de minimisation itératif. A chaque itération, l'erreur de classification est réduite d'une façon significative jusqu'à convergence menant vers l'obtention du résultat final escompté. Malgré la complexité des détails caractérisant ce type d'images, notre technique rapporte un résultat clair et cohérent avec la réalité sur le terrain.

L'étude que nous avons menée jusque là, ne s'arrête pas à ce niveau. La détection des nuages est considérée comme une étape importante dans le traitement et l'interprétation des différents paramètres météorologiques. Afin d'estimer ces paramètres, il est nécessaire séparer les nuages présents dans ces images en différentes classes selon un certain critère.

Dans le chapitre suivant, nous allons proposer une autre méthode de classification permettant, cette fois-ci, de séparer les nuages observés dans une image MSG en fonction de leur contenu en eau.

CHAPITRE 4

METHODE DE CLASSIFICATION DES NUAGES SELON LEUR CONTENU EN EAU

4.1. Préambule

Les différents travaux effectués dans le domaine de la météorologie ont permis d'élaborer plusieurs méthodes de segmentation et de classification d'images et plus particulièrement les images satellitaires dont l'analyse permet de détecter les différents types de nuages en vue d'une estimation ou d'une classification des différents paramètres météorologiques tels que le taux de précipitations dans les nuages précipitants ([Kühnlein et al 2008](#) ; [Adler et Negri 1988](#) ; [Laviola Levizzani 2011](#) ; [Levizzani et al 2004](#) ; [Lazri et al 2013](#)).

Parmi ces méthodes, certaines sont classées dans la famille des approches non supervisées telles que les méthodes des K-means ([Zahraie et Roozbahani 2011](#)) et Fuzzy c-means ([Satyanarayana et Srinivas 2011](#)) ; et d'autres appartiennent à la famille des approches supervisées comme les méthodes basées sur les SVM ([Jain et Bhatia. 2013](#); [Lee et al. 2004](#)) ; le maximum de vraisemblance ([Feidas et Giannakos 2011](#) ; [Thies et al. 2008, 2010](#)) ou encore les réseaux de neurones ([Giannakos et Feidas 2013](#)) dont le domaine d'utilisation ne cesse de s'élargir ces dernières années .

Dans ce chapitre nous allons présenter la méthode que nous avons élaborée (Mohia.Y et Ameer.S) permettant la classification des nuages selon leur contenu en eau en utilisant les données du satellite météorologique MSG. Cette méthode est basée sur les réseaux de neurones multicouches (MLP) dont les entrées correspondent, dans un premier temps, aux paramètres spectraux du radiomètre SEVIRI qui fournissent des informations sur les propriétés des nuages, et dans un second temps, à une combinaison entre ces paramètres et des

paramètres texturaux fournissant une information contextuelle des nuages. L'apprentissage des réseaux est réalisé par des données collectées par le radar de Sétif. Cette méthode est appliquée à la région nord de l'Algérie et son évaluation est réalisée en utilisant une base de données enregistrée durant les saisons pluvieuses de novembre 2006 à mars 2007 et de novembre 2001 à mars 2011.

Avant de présenter la méthodologie de notre méthode de classification des nuages d'eau selon leur contenu en eau en six classes, nous allons d'abord faire une présentation du site d'étude ainsi que les données utilisées. Les résultats obtenus après application de cette technique seront ensuite présentés, analysés puis évalués.

4.2. Présentation du site

La méthode que nous avons élaboré est appliquée à une partie du nord de l'Algérie, un pays qui se situe au nord-ouest du continent africain et plus précisément sur la rive sud de la mer méditerranéenne avec près de 1200 km de cotes. Ce pays est frontalier avec la Tunisie et la Lybie à l'Est, avec le Maroc à l'Ouest, avec le Sahara Occidental et la Mauritanie au Sud Ouest et avec le Niger et le Mali au Sud. Comme le montre la figure suivante, la zone d'étude que nous avons choisie correspond à la couverture du radar de Sétif d'un rayon de 250 km et s'étale sur une distance de 800 km de long et de 400 km de large.




Figure 4.1 Zone d'étude coïncidant avec la couverture du Radar de Sétif.

4.3. Présentations des données utilisées

Dans le cadre de notre étude, deux types de données sont utilisés: des images satellitaires et des données radar. Les données satellite sont issues du radiomètre SEVIRI du satellite MSG. Parmi les 12 canaux dont il dispose, nous avons retenu les huit suivants: VIS0.6, NIR1.6, IR3.9, WV6.2, WV7.3, IR8.7, IR10.8 et IR12.0. Les données radar collectées par le radar météorologique de Sétif se présentent sous forme d'image de taille 512x512 pixels collectées toutes les 15 minutes avec une résolution spatiale de 1km².

Nous avons divisé notre base de données en deux parties : une partie pour la phase d'apprentissage et l'autre partie pour la phase de validation. La première partie est constituée de 2109 scènes de précipitations enregistrées pendant la période allant de novembre 2006 à Mars 2007. La deuxième partie, est composée de 1936 scènes de précipitations collectées durant la période allant de Novembre 2010 à Mars 2011.

4.4. Co localisation des données Radar et Satellite

Afin de régler le problème de non correspondance entre la résolution spatiale du Radar est celle du satellite, nous avons reprojété et rééchantillonné les données radar utilisées qui sont de résolution spatiale de 1x1 km² à la résolution spatiale des données MSG qui est de 4x5 km² dans le cas de la zone d'étude que nous avons choisie.

Nous constatons aussi un décalage spatial entre ces deux types de données qui est du à des erreurs de parallaxe et des erreurs de colocalisation ([Vicente et al. 2002](#)). Ce décalage de parallaxe est causé par l'angle d'observation de la terre par le radiomètre SEVERI. Il est subi par les nuages observés par SEVIRI et peut aller jusqu'à jusqu'à 20 km par rapport aux images issues du radar météorologique ([Kühnlein et al. 2010](#)). Cette erreur est fonction de la hauteur des nuages et elle est moins importante pour les nuages stratiformes que pour les nuages convectifs.

Pour minimiser cette erreur, nous avons comparé chaque pixel radar aux 5x5 pixels de l'image MSG pour le cas des nuages hauts et aux 3x3 pixels dans le cas des nuages bas, ce qui nous permet donc d'avoir un maximum de corrélation entre les données utilisées issues du radar et du satellite.

4.5. Différenciation des taux de précipitations

Selon le model conceptuel développé par House (House 1993) des différentes parties d'un système pluvieux dominé par différents processus de précipitations et qui conduit à différentes intensités de précipitations dans les systèmes extratropicaux, les systèmes de précipitations sont divisés en différentes sous-zones (classes) en fonction des différents processus et taux de pluie (Thies et al, 2008) de la façon suivante:

- 1) **Taux très fort:** correspondent à la zone de précipitations à très forte convection des cumulonimbus(Cb) dont la réflectivité radar est supérieure à 46.0 DBZ. Le taux de précipitations est supérieur à 12 mm/h.
- 2) **Taux modéré à fort:** cette classe correspond à la zone de précipitations convective-stratiformes des Nimbostratus (Ns) dont la réflectivité radar se situe entre 42 DBZ et 46 DBZ. Le taux de précipitations dans cette partie varie de 7.5 mm/h à 12 mm/h.
- 3) **Taux modéré :** cette classe représente la zone de précipitations qui correspondent aux nuages à caractère intermédiaire entre le convectif dominant et l'advection-stratiforme. La réflectivité radar se situe entre 34 DBZ et 38 DBZ. Le taux de précipitations dans cette partie peut varier de 2.8 mm/h à 4.6 mm/h.
- 4) **Taux faible à modéré:** c'est la zone de précipitations advectiones-stratiformes (Ns) dont la réflectivité radar varie de 26 DBZ à 30 DBZ. Le taux de précipitations dans cette zone se situe entre 1.0 mm/h et 1.7 mm/h.
- 5) **Taux faible:** cette classe correspond à la zone de précipitations l'origine advection-stratiforme dont la réflectivité radar se situe entre 12 DBZ et 22 DBZ. Le taux de précipitations dans cette partie varie de 0.2 mm/h à 0.6 mm/h.
- 6) **Taux nul:** cette classe correspond à la zone de précipitations dont la réflectivité radar est inférieure à 12 DBZ. Le taux de précipitations dans cette zone est inférieur à 0.6 mm/h.

Le tableau 4.1 résume les différentes classes correspondant aux différents taux de pluie obtenues en utilisant les mesures effectuées par le radar de Sétif ainsi que la réflectivité radar correspondant à chaque classe.

N°	Classe	Taux de pluie (mm/h)	reflectivité radar (Dbz)
1	Trés forts	>12	>46.0
2	Modérés à forts	7.5 to 12.0	42 to 46
3	Modérées	2.8 to 4.6	34 to 38
4	Faibles à modérés	1.0 to 1.7	26 to 30
5	Faibles	0.2 to 0.6	12 to 22
6	Nuls	<0.1	<12

Tableau 5.4: Différentes classes correspondant aux différents taux de précipitations

4.6. Présentation et méthodologie de la technique élaborée

Dans cette partie, nous allons présenter la méthode élaborée qui permet de séparer les nuages selon leur contenu en eau en différentes classes. Notre approche est basée sur trois réseaux de neurones multicouches. Chacun de ces réseaux est constitué de 3 couches : une couche d'entrée, une couche cachée et une couche de sortie.

Dans le premier modèle (MLP-S), seuls les paramètres spectraux sont utilisés comme entrées. Dans les deux autres modèles, nous introduisons l'information texturale comme information supplémentaire à l'entrée du modèle. Elle correspond aux attributs statistiques du premier ordre pour le deuxième modèle (MLP-ST1) et à ceux du second ordre pour le troisième modèle (MLP-ST2).

La couche de sortie de chaque réseau de neurones est constituée de 6 neurones qui correspondent aux six classes définies auparavant. Dans l'étape d'apprentissage, les données issues du radar de Sétif sont utilisées afin de différencier les différents taux de pluie.

Nous allons d'abord décrire l'architecture ainsi que les paramètres utilisés dans chaque modèle, puis nous allons présenter et analyser les résultats de classification ainsi obtenus après application de chaque technique.

4.6.1. Description du premier modèle de classification (MLP-S)

Comme le montre la figure 4.2, la couche d'entrée est composée de 10 neurones représentant les dix paramètres spectraux que nous avons choisis et qui sont les plus utilisés dans ce type de classification. La couche de sortie est composée de six neurones correspondant aux six classes des différenciées par les données radar.




Figure 4.2 : Architecture du premier model de classification (MLP-S)

4.6.1.1. Choix des paramètres spectraux (couche d'entrée)

Dans les images météorologiques multispectrales, la plupart des techniques de classification des nuages précipitants développées se basent essentiellement sur la relation qui existe entre les paramètres physiques des nuages et les paramètres spectraux issus des canaux du radiomètre associé au satellite utilisé. Ces paramètres radiatifs ont été utilisés à la place des paramètres physiques des nuages.

Dans le cadre de notre étude, dix paramètres spectraux dérivés du radiomètre SEVIRI du satellite MSG décrit dans le chapitre 1 sont retenus : la température de brillance dans le canal infrarouge 1 ($T_{IR10.8}$), six différences de température de brillance entre deux canaux infrarouges ($\Delta T_{IR10.8-IR12.1}$, $\Delta T_{IR8.7-IR10.8}$, $\Delta T_{IR3.9-IR10.8}$, $\Delta T_{IR13.4-IR10.8}$, $\Delta T_{IR8.7-IR12.1}$, $\Delta T_{IR9.7-IR13.4}$), une différence de température de brillance entre un canal infrarouge et un canal vapeur d'eau ($\Delta T_{IR3.9-WV7.3}$), une différence de température de brillance entre un canal vapeur d'eau et un canal infrarouge ($\Delta T_{WV6.2-IR10.8}$) et une différence de température de brillance entre deux canaux vapeur d'eau ($\Delta T_{WV6.2-WV7.3}$).

- 1) **La température de brillance $BT_{IR10.8}$ (In1):** elle correspond à la température de brillance dans le canal infrarouge de longueur d'onde 10.8- μm . Elle permet de détecter les nuages de moyenne et haute altitude ayant une température de luminosité de 10,8 μm inférieure à la température de luminosité de la surface du ciel clair. Elle permet également d'indiquer l'étendue verticale du nuage car, en général, la température de luminosité du système dépend de la hauteur du nuage ([Eumetsat](#)).
- 2) **La différence de température de brillance $\Delta T_{IR10.8-IR12.1}$ (In2):** cette mesure peut être utilisée sur toutes les surfaces et pour tout éclairage solaire. C'est un bon indicateur de l'épaisseur optique du nuage et elle est très efficace pour faire une discrimination entre les nuages cumuliformes épais les cirrus minces. Les cumulus présentent une faible valeur de DTB tandis que les cirrus fournissent une grande valeur de DTB. Les nuages convectifs optiquement épais et profond sont donc associés à de la pluie ([Eumetsat](#)).
- 3) **La différence de température de brillance $\Delta T_{IR8.7-IR10.8}$ (In3):** ce paramètre permet de détecter les cirrus minces sur toutes les surfaces pour toute illumination solaire. Il est basé sur le fait que les nuages semi-transparents élevés sont caractérisés par une différence relativement élevée de cette mesure par rapport aux valeurs de la surface. Les informations sur la phase de nuage peuvent aussi être obtenues en utilisant cette mesure. Les simulations de transfert radiatif montrent que pour les nuages de glace, cette différence tend à être positive dans le signe, alors que pour les nuages d'eau de bas niveau, elle tend à être faiblement négative ([Eumetsat](#)).
- 4) **La différence de température de brillance $\Delta T_{IR3.9-IR10.8}$ (In4):** le canal de 3,9 μm est utilisé lorsque les observations du canal 1,6 μm ne sont pas disponibles. Cette

différence permet de détecter les nuages froids et les nuages hauts semi-transparents. Elle est basée sur le fait que la contribution des motifs relativement chauds à la température de luminosité est plus élevée à 3,9 μm qu'à 10,8 μm . Elle est aussi fonction de la hauteur et de l'épaisseur du nuage ([Eumetsat](#)).

- 5) ***La différence de température de brillance $\Delta T_{IR13.4-IR10.8}$ (In5):*** elle permet de détecter le développement de la croissance des nuages cumulus et d'estimer la hauteur des nuages dans les images MSG. Les fortes valeurs négatives de ce paramètre correspondent aux nuages de bas niveau parce que l'absorption du CO₂ au-dessus d'eux réduit la température à 13,4. Les petites valeurs négatives de cette BTB correspondent aux cumulus croissants puisque leurs sommets sont au-dessus de la majeure partie de la couche de CO₂ ([Eumetsat](#)).
- 6) ***La différence de température de brillance $\Delta T_{IR8.7-IR12.1}$ (In6):*** ce paramètre peut être utilisé pour avoir des informations sur l'épaisseur optique des nuages. Les valeurs positives correspondent à l'épaisseur optique du nuage élevé due aux processus de diffusion et à la dépendance à la taille des particules qui est plus forte dans le canal de 8,7 μm par rapport au canal de 12,1 μm . En revanche, ses valeurs négatives correspondent à l'épaisseur optique du nuage faible, car l'absorption de la vapeur d'eau dans le canal de 8,7 μm est supérieure à celle du canal de 12,1 μm ([Eumetsat](#)).
- 7) ***La différence de température de brillance $\Delta T_{IR9.7-IR13.4}$ (In7):*** donne des informations sur la hauteur du nuage. Pour les nuages de faible intensité, la différence ($\Delta T_{9.7-13.4}$) produit des valeurs négatives car les températures au canal 9,7 μm sont plus froides que les températures au canal de 13,4. Pour les nuages élevés sur 12 km, la température de luminosité à 9,7 μm présente des valeurs significativement plus élevées que la température de luminosité à 13,4 μm ([Eumetsat](#)).
- 8) ***La différence de température de brillance $\Delta T_{WV6.2-WV7.3}$ (In8):*** elle permet de détecter la hauteur du nuage et de fournir des informations sur la détection précoce de l'activité convective. Les valeurs négatives de cette différence de température correspondent à des nuages bas. Les nuages très hauts qui peuvent atteindre la stratosphère tendent à donner des différences de température positives ([Eumetsat](#)).

9) **La différence de température de brillance $\Delta T_{WV6.2-IR10.8}$ (In9):** ce paramètre permet de distinguer entre les nuages hauts et les nuages bas et moyens. Les températures des nuages de faible intensité au niveau du canal de 6,2 μm sont inférieures à leurs températures actuelles supérieures aux nuages. Mais au niveau du canal de fenêtre de 12,0 μm , leurs températures au-dessus de la surface des nuages sont représentatives de la température réelle des nuages, puisque l'atmosphère est transparente à cette longueur d'onde. En conséquence, pour les nuages de bas niveau, la différence de température ($\Delta T_{WV6.2-IR10.8}$) tend à être très négative. (Eumetsat).

10) **La différence de température de brillance $\Delta T_{TWV3.9-IR7.3}$ (In10):** elle présente des caractéristiques généralement similaires à celle du paramètre précédent ($\Delta T_{WV6.2-IR10.8}$). Les valeurs de différence inférieures correspondent aux nuages d'épaisseur optique faible. En revanche, les grandes particules avec une épaisseur optique élevée donnent des valeurs de différence élevées (Eumetsat).

La couche d'entrée est donc constituée de dix neurones qui correspondent aux dix paramètres spectraux notés d'In1 à In10 décrits ci-dessus.

4.6.1.2. La couche de sortie

Elle est composée de six neurones correspondant aux six classes qui représentent les différentes intensités de précipitations décrites auparavant, notées *Out1*, *Out2*, *Out3*, *Out4*, *Out5* et *Out6* et résumées dans le tableau suivant :

Sortie	Classe	Signification
Out1	Classe1	Très fortes
Out2	Classe2	De modérées à fortes
Out3	Classe3	Modérées
Out4	Classe4	De faibles à modérées
Out5	Classe5	Faibles
Out6	Classe6	Nulles

Tableau 4.2: Paramètres de sortie du modèle.

4.6.1.3. La couche cachée

Afin de déterminer le nombre de neurones constituant cette couche ainsi que les poids de connexion entre les neurones, un apprentissage avec une base de données comportant 2109 scènes de précipitations a été effectué. La figure (4.3) montre que pour les modèles (MLP-ST1 et MLP-ST2), 20 neurones cachés est le nombre optimal permettant de minimiser à 1,6 l'erreur quadratique moyenne RMSE après 700 itérations. Nous avons donc fixé à 20 le nombre de neurones de la couche cachée.




Figure 4.3: Variation de l'erreur RMSE en fonction du nombre de neurones de la couche cachée et du nombre d'itérations d'apprentissage

Les valeurs du pas d'apprentissage (η) ainsi que l'inertie (α) du réseau sont fixées respectivement à 0,4 et à 0,6.

4.6.2. Description du deuxième modèle de classification (MLP-ST)

Dans ce cas, l'approche est basée sur une utilisation conjointe entre l'information spectrale et texturale des images MSG. Deux implémentations en réseaux de neurones sont ainsi utilisées. La première (MLP-ST1) fait appel aux attributs statistiques du premier ordre alors que la deuxième (MLP-ST2) utilise les attributs statistiques du second ordre.

4.6.2.1. Modélisation avec des attributs statistiques du premier ordre (MLP-ST1)

Le deuxième type de paramètres que nous avons choisis sont des attributs de texture du premier ordre qui sont largement utilisés dans la segmentation et la classification des images satellitaires. Les attributs qu'il faut choisir ainsi que leur nombre en vue de réussir ces

opérations, peuvent varier d'une application à une autre. L'utilisation de tous les attributs peut conduire à des temps de traitement très importants et la limitation aléatoire de leur nombre peut produire de mauvais résultats de classification. Une étape de sélection d'attributs les plus pertinents doit être envisagée afin de remédier à ces inconvénients.

4.6.2.1.1. Choix et sélection des attributs de texture

L'un des problèmes majeurs auxquels nous sommes souvent confrontés lors du développement d'un système de classification d'image est le problème de la sélection des meilleurs attributs à utiliser pour cette opération. La sélection des attributs les plus pertinents et donc représentatifs est une étape très difficile à réaliser en vue d'effectuer une bonne classification. Parmi les différentes méthodes et outils de sélection d'attributs qui existent dans la littérature, nous pouvons citer les plus simples d'entre elles, celles qui sont basées sur le critère de redondance ou la corrélation des attributs de texture sur lequel est basée la méthode de sélection que nous avons utilisée.

4.6.2.1.2. Critère basé sur la corrélation entre attributs

Ce critère que nous avons choisi est la méthode de sélection des attributs basée sur les coefficients de corrélation et utilisée par *Rosenberger* ([Rosenberger,1999](#)) qui nous permet alors de ne conserver que les attributs les plus pertinents capables de délivrer de bons résultats de classification. Le principal objectif de cette méthode consiste à évaluer la redondance d'informations entre attributs pour nous permettre de ne sélectionner et de ne conserver que les moins redondants car, et comme nous l'avons dit précédemment, ces attributs doivent être discriminants et leur nombre doit être le plus restreint possible.

Le coefficient de corrélation linéaire exprime la redondance qui existe entre deux attributs. La corrélation notée $cor(a_i ; a_j)$ entre deux attributs a_i et a_j est calculée par l'expression suivante :

$$cor(a_i ; a_j) = \frac{\sum_{i,j} (a_i - \bar{a}_i)(a_j - \bar{a}_j)}{\sqrt{\sum_i (a_i - \bar{a}_i)^2} \sqrt{\sum_j (a_j - \bar{a}_j)^2}} \quad (4.1)$$

Où : $\bar{a}_i$ représente la moyenne de l'attribut a_i .

Une matrice de corrélation symétrique qui possède des éléments dans l'intervalle $[-1, 1]$ est ainsi obtenue. Elle nous permet de sélectionner un sous-ensemble d'attributs ayant une redondance mutuelle acceptable.

On dit qu'un attribut a_i est redondant par rapport à l'attribut a_j lorsque la valeur absolue de la corrélation entre ces deux attributs est proche de 1. Comme le but de la méthode est d'identifier les attributs qui n'apportent aucune information supplémentaire dans la classification, seule la valeur absolue du coefficient de corrélation est considérée pour quantifier la redondance entre deux attributs. Le même résultat est donc obtenu lorsque la classification est faite à partir de deux attributs (a_1, a_2) ou $(a_1, -a_2)$. Si la valeur absolue du facteur de corrélation de deux attributs est négligeable, on dit alors qu'ils sont pertinents ou complémentaires.

Comme l'a proposé *Rosenberger*, la valeur du seuil S correspondant à la redondance maximale tolérée pour deux attributs, est fixée dans ce cas à $S=0.95$. Puis, nous avons représenté un tableau pour mettre en évidence les coefficients de corrélation supérieurs ou égaux à 0.95 afin d'identifier et pointer les attributs fortement corrélés qui sont : Energie et Moyenne ; Contraste et Moyenne ; Energie et Entropie.

Ensuite, pour chaque paire d'attributs (a_i, a_j) fortement corrélés, on doit écarter celui qui est le plus corrélé aux autres en utilisant le critère le critère suivant :

Si $\sum_k |cor(a_k; a_j)| > \sum_k |cor(a_k; a_i)|$ alors on écarte l'attribut a_i , sinon on écarte l'attribut a_j .

L'application de ce critère sur les attributs donnés par les estimateurs statistiques nous permet de ne conserver que ceux qui ont une redondance admissible réglée par la valeur du seuil. Ainsi, parmi les dix attributs que nous avons fixés au départ, seuls sept d'entre eux sont retenus pour la classification. Il s'agit : du contraste, de la variance, du coefficient de variation, de l'énergie, du kurtosis, du skewness et de l'entropie. Ce sont donc ces attributs restants qui seront utilisés comme deuxième type d'entrée du modèle afin de répartir l'image en différentes classes.

Le numéro d'entrée ainsi que l'équation régissant chacun de ces paramètres, sont donnés dans le tableau 4.3.

<i>Entrée</i>	<i>Paramètre de texture</i>	<i>Signification</i>
In11	$\text{Cont} = \frac{1}{N} \sum_{i=0}^{N_g} i^2 h(i)$	Contraste
In12	$\sigma^2 = \frac{1}{N} \sum_{i=0}^{N_g} (i - m)^2 h(i)$	Variance
In13	$cv = \frac{\sigma}{m}$	coefficient de variation
In14	$\text{Eng} = \frac{1}{N} \sum_{i=0}^{N_g} h^2(i)$	Energie
In15	$Ku = \frac{1}{N\sigma^4} \sum_{i=0}^{N_g} (i - m)^4 h(i)$	Kurtosis
In16	$Sk = \frac{1}{N\sigma^3} \sum_{i=0}^{N_g} (i - m)^3 h(i)$	Skewness
In17	$\text{Ent} = \frac{1}{N} \sum_{i=0}^{N_g} h(i) \log(h(i))$	Entropie

Tableau 4.3: Paramètres texturaux d'entrées du modèle (MLP-ST1)

Le schéma de cette modélisation est illustré par la figure suivante:




Figure 4.4 : Architecture du deuxième modèle de classification (MLP-ST1)

4.6.2.2. Modélisation avec des attributs statistiques du deuxième ordre (MLP-ST2)

Les paramètres de texture que nous avons utilisés dans cette technique sont des attributs statistiques du second ordre calculés à partir des matrices de cooccurrence décrites dans le chapitre précédent. Le calcul de cette matrice s'est fait sur la base d'un certain nombre de paramètres que nous allons présenter dans la section suivante.

4.6.2.2.1. Paramètres utilisés pour le calcul de la matrice de cooccurrence

Quatre paramètres de base doivent être fixés afin de déterminer la matrice de cooccurrence. Il s'agit de la taille de la matrice, la taille de la fenêtre d'analyse, la distance entre pixels et la direction d'étude.

a) Choix de la taille de la matrice de cooccurrence

Comme la taille d'une matrice de cooccurrence qui prend en compte toute la dynamique de niveaux de gris est trop grande, une étape de quantification des niveaux de gris est donc nécessaire pour avoir une matrice de taille pas trop élevée. Ceci nous permet de réduire le temps de calcul dans la mise en œuvre de cette méthode et rendre ainsi les résultats encore plus significatifs. Cependant, une diminution arbitraire de cette taille peut aussi causer une perte d'information utile. C'est pour cette raison que le choix du type de quantification ainsi que le nombre de niveaux est crucial pour des images offrant une dynamique élevée comme il est le cas des images que nous avons utilisées.

Parmi les différents types de quantification envisagés (linéaire, logarithmique, ...), nous avons opté pour une quantification adaptative nous permettant de diminuer le nombre de niveaux de gris tout en minimisant l'erreur de quantification. On a donc par la suite choisi de quantifier à 8 niveaux ce qui permet d'avoir une image quantifiée proche de l'originale.

b) Choix de la taille de la fenêtre

Les performances et l'efficacité d'une méthode basée sur une analyse de textures utilisant des attributs calculés à partir de la matrice de cooccurrence dépendent essentiellement de la taille de la fenêtre d'analyse sur laquelle les calculs sont ont été effectués. Une taille trop petite de cette fenêtre ne permet pas d'extraire assez d'information

spatiale, en revanche une taille trop grande peut conduire soit à son chevauchement sur deux types de couvertures ce qui mène à l'introduction d'une information spatiale erronée, soit à la création des zones de transition trop larges entre des régions voisines. Nous devons donc choisir une taille optimale de cette fenêtre contenant un maximum d'information. Afin de faciliter ce choix, nous allons utiliser la méthode basée sur le calcul du coefficient de variation d'un paramètre de texture donné pour chaque classe en fonction de la taille de la fenêtre. La taille de la fenêtre à partir de laquelle la valeur du coefficient de variation commence à se stabiliser pour la majorité des classes (tout en ayant la plus faible valeur) sera choisie comme taille optimale de la fenêtre d'analyse.

Cependant, nous avons remarqué que la valeur du coefficient de variation ne se stabilisait pas à cause de la trop forte dynamique de l'image de départ. Ceci rend très difficile, pour ne pas dire impossible, la recherche de la taille optimale de la fenêtre recherchée. Pour extraire cette dynamique et nous permettre ainsi de déterminer la taille de la fenêtre adéquate, une différence entre l'image de départ et l'image moyennée est calculée et le résultat trouvé représente donc notre image de départ à partir de laquelle, nous avons calculé le coefficient de variation (σ/m) sur les différentes classes. Nous avons choisi la valeur 3 comme taille initiale de la fenêtre et nous l'avons fait varier. Nous avons remarqué qu'à partir d'une taille de fenêtre égale à 7, ce coefficient de variation commence à se stabiliser et cette stabilité nous paraît évidente quand la taille de la fenêtre est égale à 9. Les différents attributs de texture utilisés sont ainsi déterminés à travers des fenêtres de taille 9×9 .

c) Choix de la direction

Afin de prendre en compte les effets de directivité un bon choix de l'angle de direction θ s'impose. En l'absence de cette précision, une texture orientée dans deux directions différentes (par exemple direction nord-sud et direction est-ouest) auront automatiquement des descriptions différentes.

Dans la pratique, la cooccurrence n'est calculée que pour quelques valeurs de θ à cause du problème de complexité. Dans notre application, nous avons opté pour la méthode de *Haralick et al* qui consiste à faire la moyenne des valeurs pour les quatre directions suivantes : (0° , 45° , 90° et 135°).

d) Choix de la distance entre pixels

La distance d entre les pixels qu'il faut choisir dépend particulièrement de la nature de la texture de l'image à traiter. Cette distance peut être choisie grande pour une image ayant une texture grossière. Comme les images contiennent généralement à la fois des textures fines et des textures grossières, le choix d'une grande distance d peut donner de bon résultats pour certaines textures d'une image mais pas pour d'autres textures de la même image. Il n'y a donc pas de méthode particulière permettant de déterminer de façon précise une distance pertinente entre pixels de l'image, et par conséquent, le calcul des matrices de cooccurrence pour tous les déplacements possibles devient évidemment irréalisable. En pratique, il a été démontré que le choix d'une distance courte donne souvent des résultats satisfaisants. Et comme les textures les plus fines sont difficiles à identifier, la distance entre pixels est généralement fixée à un pixel.


4.6.2.2.2. Choix et sélection des attributs de cooccurrences

Parmi les quatorze paramètres descriptifs des textures pouvant être extraits à partir de la matrice de cooccurrence et définis par Haralick ([Haralick et al.1973](#)), nous avons retenu initialement neuf attributs les plus souvent utilisés en télédétection ([Sali et Wolfson,1992](#)) ([Kayitakire et al.2002](#)) et qui sont: la moyenne, la variance, la corrélation, le contraste, le second moment angulaire (énergie), la directivité, l'entropie, l'homogénéité locale (moment de différence inverse) et l'uniformité.

Afin de ne conserver que les paramètres représentatifs les plus pertinents permettant de réaliser une bonne classification et réduire le temps de traitement, nous avons appliqué, sur ces neuf paramètres, le même critère de sélection que celui utilisé pour choisir les meilleurs attributs donnés par les estimateurs statistiques du premier ordre.

L'application de ce critère, nous permet de limiter à cinq le nombre de paramètres pertinents les moins redondants qui seront utilisés comme deuxième type d'entrées du modèle. Il s'agit donc: du contraste, de la corrélation, de l'entropie, de l'homogénéité et du second moment angulaire (ASM) qui représentent les entrées *In11* à *In15* du modèle et représentées dans le tableau 4.4. La figure 4.5 montre le schéma de cette modélisation.

<i>Entrée</i>	<i>Paramètre de texture</i>	<i>Signification</i>
In11	$Cont = \sum_{i=0}^{Ng-1} \sum_{j=0}^{Ng-1} (i-j)^2 x_{ij}$	Contraste
In12	$Cor = \sum_{i=0}^{Ng-1} \sum_{j=0}^{Ng-1} \frac{(i-\mu_x)(j-\mu_y)}{\sqrt{\sigma_x \sigma_y}} x_{ij}$	Corrélation
In13	$Ent = \sum_{i=0}^{Ng-1} \sum_{j=0}^{Ng-1} x_{ij} \log x_{ij}$	Entropie
In14	$Hom = \sum_{i=0}^{Ng-1} \sum_{j=0}^{Ng-1} \left[\frac{x_{ij}}{1 + (i-j)^2} \right]$	Homogénéité
In15	$ASM = \sum_{i=0}^{Ng-1} \sum_{j=0}^{Ng-1} x_{ij}^2$	Second Moment Angulaire

Tableau 4.4: Entrées texturales du modèle (MLP-ST2)**Figure 4.5 :** Architecture du deuxième modèle de classification (MLP-ST2)

4.7. Résultats de la classification et évaluation des performances de la méthode

Dans cette partie, nous allons présenter les résultats obtenus par les techniques que nous avons décrites dans les sections précédentes. Chacune de ces trois techniques est appliquée dans un premier temps à une seule situation instantanée avant d'être généralisée à l'ensemble des situations observées durant la période choisie. Les résultats délivrés par la sortie de chaque modèle dans chaque cas, seront ensuite comparés aux données instantanées radar collectées pendant la même période dans le but d'évaluer les performances de ces modèles.

4.7.1. Résultats de la classification avec le modèle (MLP-S)

4.7.1.1. Application du modèle à une seule situation de précipitations

Parmi toutes les situations de précipitations disponibles dans notre base de données, nous avons choisi celle prise le 03 Janvier 2011 à 14 :00 UTC. Comme le montre la figure 5.13(a), cette situation représente une image de température de brillance prise dans le canal infrarouge IR10.8. Le nombre de pixels identifiés par cette méthode avec ceux observés par le radar pour cette situation est donné dans le tableau suivant :

	Classe 1	Classe 2	Classe 3	Classe 4	Classe 5	Classe 6
MLP-S	1402	1715	2134	437	412	3527
Radar	1355	1623	2378	712	799	3422

Tableau 4.5: Nombre de pixels identifiés dans chaque classe en utilisant le modèle (MLP-S)

➤ Analyse statistique

Afin d'évaluer les performances de l'approche proposée, nous avons calculé six paramètres statistiques les plus utilisés et déterminés par comparaison de la méthode de classification aux observations radar et qui sont définis par les équations suivantes :

- **Le Biais (Bias)** : il décrit le rapport entre l'estimation par notre méthode et l'observation par Radar d'un événement précipitant. Il est donné par cette équation :

$$Bias = \frac{a + b}{a + c} \quad (4.2)$$

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

$$POD = \frac{a}{a + c} \quad (4.3)$$

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

$$POFD = \frac{c}{c + d} \quad (4.4)$$

- **La fausse alarme (FAR):** c'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 :

$$FAR = \frac{b}{a + b} \quad (4.5)$$

- **Indice de réussite cruciale (CSI) :** indique 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 :

$$CSI = \frac{a}{a + b + c} \quad (4.6)$$

Les différentes comparaisons peuvent être résumées par la table de contingence suivante:

	Observees par le radar			
Identifies par la technique		Class(i)	No class(i)	Total
	Class(i)	a	b	a+b
	No class(i)	c	d	c+d
	Total	a+c	b+d	a+b+c+d=n

Tableau 4.6: Différentes combinaisons de la table de contingence

L'évaluation de la méthode a été réalisée en comparant les résultats obtenus avec les données instantanées collectées par le radar.

Les paramètres de vérification sont calculées pour cette situation instantanée de précipitation datée du 03 janvier 2011 à 14h :00 UTC pour les six classes et les résultats obtenus sont représentés dans le tableau suivant :

	POD (%)	POFD (%)	FAR (%)	BIAS	CSI (%)	PC (%)
Classe(1)	80	13	30	1.3	64	90
Classe(2)	75	16	39	1.4	55	90
Classe(3)	60	22	41	0.7	58	88
Classe(4)	52	24	42	0.6	50	89
Classe(5)	60	35	45	0.4	52	88
Classe(6)	77	8	23	1.4	70	92
Valeur Optimale	100	00	00	1	100	100

Tableau 4.7: Résultats de l'évaluation statistique pour une situation avec MLP-S

En observant les valeurs de ce tableau, plusieurs constations peuvent être faites. Les résultats de l'identification des classes peuvent être considérés acceptables comme le montre les valeurs du POD qui varient de 60% à 80% et les faibles valeurs des paramètres POFD et FAR qui varient respectivement de 8% à 35% et de 23% à 45%. Le BIAS indique une légère surestimation des : classe(1), classe(2) et classe(6), et une légère sous estimation pour les : classe(3), classe(4) et classe(5). Pour les autres paramètres, à savoir CSI et PC, leurs valeurs calculées pour les différentes classes, indiquent que la marge peut être considérée acceptable.

Néanmoins, la plupart de ces valeurs restent un peu loin des celles attendues à partir desquelles on peut qualifier l'approche de réellement performante pouvant délivrer des résultats proches voire identiques à ceux des sorties de références. Cela est remarquable à travers les valeurs représentées dans le tableau 5.8 indiquant le nombre de pixels appartenant à chaque classe identifiée par les deux méthodes.

En effet, nous remarquons que le nombre de pixels identifiés par la technique (MLP-S) ne correspond pas exactement à ceux identifiés par le radar, en prenant en compte aussi bien chaque classe individuellement que la totalité des classes. La différence est estimée à un déficit de 7% par rapport à la totalité des pixels devant être identifiés.

4.7.1.2. Application du modèle à une période de situations

La base de données utilisée pour l'évaluation de notre technique est constituée d'images MSG et Radar prises pendant la période de Novembre 2010 à Mars 2011 au nord de l'Algérie. Le nombre de scènes est de 1936. Les résultats obtenus sont aussi comparés avec les données collectées par le radar.

L'évaluation des performances de cette méthode pour ces différentes situations de précipitations est réalisée par analyse des mêmes paramètres statistiques utilisés dans le cas d'une seule situation de précipitations. Le tableau suivant montre le résultat d'une comparaison pixel par pixel entre les pixels observés par le radar et ceux classifiés par notre méthode avec le modèle (MLP-S) durant toute la période choisie:

	<i>POD</i> (%)	<i>POFD</i> (%)	<i>FAR</i> (%)	<i>BIAS</i>	<i>CSI</i> (%)	<i>PC</i> (%)
<i>Classe(1)</i>	78	14	29	1.3	71	90
<i>Classe(2)</i>	76	15	35	1.4	65	92
<i>Classe(3)</i>	70	19	38	0.7	63	88
<i>Classe(4)</i>	69	20	39	0.7	63	91
<i>Classe(5)</i>	73	34	44	0.5	57	85
<i>Classe(6)</i>	87	8	21	1.4	74	91

Tableau 4.8: Résultats de l'évaluation statistique pour une période avec MLP-S

En observant les valeurs du tableau 4.8, nous remarquons que ce modèle donne de bons résultats pour les classes dont les valeurs du PC se situent entre 88% et 92% et qu'on peut considérer comme des pixels correctement identifiés. Les meilleures valeurs sont celles obtenues pour les classes : 1 et 2 qui sont de l'ordre de 90% et 92% respectivement.

D'autre part, la valeur du paramètre Biais fournit une surestimation pour les trois classes 1,2 et 6 et une sous estimation pour les classes 4 et 5. Mais, il exprime une distribution globale équitable d'une valeur de 1.3 entre les différentes classes.

Une meilleure performance de cette méthode est enregistrée pour les situations dominées par les précipitations convectives qui correspondent aux classes : 1 et 2. Les valeurs des paramètres statistiques de ces classes sont respectivement: POD (78% et 76%), POFD

(14% et 15%) et FAR (29% et 35%).

Cependant, lorsque les précipitations sont de nature advectives-stratiformes qui correspondent aux classes 3, 4 et 5, cette performance est remarquablement diminuée. Les valeurs de ces paramètres statistiques calculés pour ces classes sont respectivement: POD (70%, 69% et 73%), POFD (19%, 20% et 34%) et FAR (38%, 39% et 44%). En considérant toutes les situations, les valeurs de POD, POFD, et FAR sont respectivement de l'ordre de: 80%, 13% et 25%. Les valeurs du paramètre CSI indique que les classes 1 et 2 sont les mieux identifiées.

Les différentes valeurs présentées dans les tableaux précédents sont globalement acceptables, mais peuvent bien être améliorées pour les rapprocher des valeurs optimales. Cela, nous amène donc à rechercher d'autres techniques pour améliorer cette solution et c'est ainsi que nous avons introduit un autre modèle (MLP-ST) basée à la fois sur l'information spectrale et texturale des images étudiées.

4.7.2. Résultats de la classification avec le modèle (MLP-ST1)

Dans ce modèle, nous avons introduit l'information texturale représentée par des attributs statistiques du premier ordre comme information supplémentaire pour améliorer le résultat de la classification.

Afin de pouvoir faire une comparaison objective et démontrer l'apport de cette information sur le résultat final de classification, nous allons appliquer cette méthode de la même façon aux mêmes données utilisées dans le premier modèle.

4.7.2.1. Application du modèle à une seule situation de précipitations

Le résultat de comparaison entre le nombre de pixels identifiés par ce modèle avec ceux observés par le radar pour la même situation est donné dans le tableau 4.9 suivant :

	Classe 1	Classe 2	Classe 3	Classe 4	Classe 5	Classe 6
MLP-ST1	1436	1748	2153	462	434	3565
Radar	1355	1623	2378	712	799	3422

Tableau 4.9: Nombre de pixels identifiés dans chaque classe en utilisant le modèle (MLP-S)

Les mêmes paramètres de vérification sont calculés pour cette situation pour les six classes et les résultats obtenus sont représentés dans le tableau suivant :

	<i>POD (%)</i>	<i>POFD (%)</i>	<i>FAR (%)</i>	<i>BIAS</i>	<i>CSI (%)</i>	<i>PC (%)</i>
Classe(1)	82	11	29	1.2	68	93
Classe(2)	79	14	36	1.3	63	92
Classe(3)	68	18	36	0.8	62	90
Classe(4)	66	20	40	0.7	62	91
Classe(5)	63	33	44	0.5	57	90
Classe(6)	86	6	20	1.2	77	95

Tableau 4.10: Résultats de l'évaluation statistique pour une situation avec MLP-ST1

Les nouvelles valeurs calculées des mêmes paramètres statistiques, indiquent une légère augmentation du paramètre POD qui varie, dans ce cas, entre 63% et 86%, accompagnée d'une légère diminution des paramètres POFD et FAR dont les nouvelles valeurs varient respectivement entre 6% et 33% et entre 20% et 44%. Le paramètre BIAS indique toujours une légère surestimation (1.2 et 1.3) des : classe(1), classe(2) et classe(6), et une légère sous estimation (entre 0.5 et 0.8) pour les : classe(3), classe(4) et classe(5). Les paramètres CSI et PC dont la marge des valeurs calculées pour la totalité des classes est de 57% à 77% pour le premier et de 90% à 95% pour le deuxième, restent toujours acceptables.

Nous constatons aussi que le nombre de pixels mal classés a diminué pour atteindre 5% d'écart de la valeur de référence identifiée par le radar.

Par conséquent, l'identification des classes avec ce modèle (MLP-ST1) qui introduit l'information texturale du premier ordre, est meilleure qu'avec le premier modèle (MPL-S) dont l'entrée est basée uniquement sur l'information spectrale.

Toutes ces constatations, nous amène à dire que l'introduction de l'information texturale à l'entrée du modèle a conduit à augmenter les performances de la méthode développée et à améliorer les résultats de la classification.

4.7.2.2. Application du modèle à une période de situations

Nous présentons également les résultats obtenus en appliquant ce principe à la même période que celle choisie dans le premier modèle. Le résultat d'une comparaison pixel par pixel entre les pixels observés par le radar et ceux classifiés par ce modèle durant toute la période choisie est donné dans le tableau suivant :

	<i>POD (%)</i>	<i>POFD (%)</i>	<i>FAR (%)</i>	<i>BIAS</i>	<i>CSI (%)</i>	<i>PC (%)</i>
Classe(1)	82	10	27	1.2	74	96
Classe(2)	78	13	32	1.3	69	94
Classe(3)	71	17	37	0.8	65	93
Classe(4)	70	19	37	0.7	67	92
Classe(5)	65	32	42	0.7	60	88
Classe(6)	89	7	21	1.3	80	95

Tableau 4.11: Résultats de l'évaluation statistique pour une période avec MLP-ST1

Les valeurs de ce tableau montrent que ce modèle présente aussi des améliorations au niveau des résultats calculés sur une période de précipitations comme pour le cas d'une seule situation de précipitations. Nous remarquons que la méthode développée donne de bons résultats des classes pour lesquelles les valeurs du PC se situent entre 88% et 96% et qu'on peut considérer comme des pixels correctement identifiés. Les meilleures valeurs sont celles obtenues pour les classes: 1, 2 et 6 et qui sont de l'ordre de 96%, 94% et 95% respectivement.

La nouvelle valeur du paramètre Biais calculée pour toute cette période indique, cette fois-ci, une distribution globale équitable d'une valeur de 1.2 entre les différentes classes d'intensités de précipitations avec une surestimation pour les classes 1 et 2 et une sous estimation pour les classes 3 et 5.

Ce modèle offre la meilleure performance pour les classes 1 et 2 qui représentent les situations dominées par les précipitations convectives. Les nouvelles valeurs des paramètres statistiques de ces classes sont respectivement: POD (82% et 78%), POFD (10% et 13%) et FAR (27% et 32%). Cette méthode devient moins performante pour les classes 3, 4 et 5 qui correspondent aux précipitations de nature advectives-stratiformes mais avec des valeurs meilleures que celles calculées dans le cas de la première méthode basée uniquement sur les

paramètres spectraux. Les valeurs de ces paramètres statistiques calculés pour ces classes sont respectivement: POD (71%,70% et 65%), POFD (17%, 19% et 32%) et FAR (37%,37% et 42%). En considérant toutes les situations, nous constatons également une amélioration de ces paramètres qui sont respectivement de l'ordre de : 83%,11% et 21%.

Aussi, comme indiqué par les valeurs du paramètre CSI, les classes 1 et 2 sont correctement identifiées confirmant ainsi que notre technique est bien adaptée aux systèmes convectifs. Concernant les autres classes associées aux situations de précipitations advectives-stratiformes, les valeurs de ce paramètre calculées sont aussi acceptables.

4.7.3. Résultats de la classification avec le modèle (MLP-ST2)

4.7.3.1. Application du modèle à une seule situation de précipitations

Le résultat de comparaison entre le nombre de pixels identifiés par cette méthode avec ceux observés par le radar pour la même situation est donné dans le tableau suivant:

	Classe 1	Classe 2	Classe 3	Classe 4	Classe 5	Classe 6
MLP-ST2	1415	1761	2172	642	463	3536
Radar	1355	1623	2378	712	799	3422

Tableau 4.12: Nombre de pixels identifiés dans chaque classe en utilisant le modèle (MLP-S)

Le tableau 4.13 contient les mêmes paramètres de vérification qui sont calculées pour cette situation instantanée de précipitation datée du 03 janvier 2011 à 14h :00 UTC :

	POD (%)	POFD (%)	FAR (%)	BIAS	CSI (%)	PC (%)
Classe(1)	84	9	26	1.1	72	97
Classe(2)	81	12	34	1.2	69	95
Classe(3)	72	16	36	0.8	66	93
Classe(4)	71	18	38	0.8	66	93
Classe(5)	65	32	42	0.6	59	92
Classe(6)	89	4	18	1.2	79	98

Tableau 4.13: Résultats de l'évaluation statistique pour une situation avec MLP-ST2

4.7.3.2. Application du modèle à une période de situations

Le résultat d'une comparaison pixel par pixel entre les pixels avec le modèle (MLP-ST2) durant toute la période choisie est donné dans le tableau suivant:

	<i>POD (%)</i>	<i>POFD (%)</i>	<i>FAR (%)</i>	<i>BIAS</i>	<i>CSI (%)</i>	<i>PC (%)</i>
<i>Classe(1)</i>	85	8	25	1.1	76	98
<i>Classe(2)</i>	80	11	31	1.3	71	97
<i>Classe(3)</i>	72	15	35	0.9	67	96
<i>Classe(4)</i>	73	17	36	0.9	69	95
<i>Classe(5)</i>	68	30	41	0.6	62	91
<i>Classe(6)</i>	91	6	19	1.1	83	98

Tableau 4.14: Résultats de l'évaluation statistique pour une période avec MLP-ST2

Les valeurs contenues dans ces tableaux, calculées aussi bien pour une seule situation que pour une période de situations, confirment les résultats trouvés auparavant avec une légère amélioration par rapport au modèle (MLP-ST1) et une nette amélioration par rapport au modèle (MPL-S).

L'introduction de l'information texturale du deuxième ordre permet à la fois de réduire le nombre d'entrées de textures du modèle, de réduire le nombre de pixels mal classés et d'améliorer considérablement les valeurs des paramètres statistiques calculées pour les différentes classes.

En effet, dans le modèle (MLP-ST1) sept entrées représentant les paramètres de texture ont été utilisées alors que dans ce modèle (MLP-ST2) le nombre de ces entrées est réduit à cinq.

Aussi, les zones contenant les pixels mal classés ont été remarquablement réduites, ce qui prouve que la plus part des pixels ont été affectés aux différentes classes. Ceci, explique que les attributs statistiques du deuxième ordre qui prennent en considération la notion de voisinage entre pixels, sont les mieux indiqués et adaptés pour ce type de classification que ceux du premier ordre.

L'analyse statistique faite sur les différentes classes dans les deux cas donne de meilleurs résultats que ceux calculés auparavant. Les valeurs du paramètre varient entre 91% et 98% et celles du paramètre CSI varient entre 62% et 83%. Les meilleures valeurs sont toujours celles obtenues pour les classes : 1 et 2 mais qui sont encore améliorées pour atteindre respectivement 98% et 97% pour le paramètre PC et 76% et 71% pour le paramètre CSI. Les nouvelles valeurs des autres paramètres statistiques de ces mêmes classes sont respectivement : POD (85% et 80%), POFD (8% et 11%) et FAR (25% et 31%). La valeur du paramètre BIAIS indiquant une légère sur estimation des ces classes reste très proche de la valeur globale qui est de 1.1.

D'un autre coté, nous remarquons une diminution des performances de cette méthode dans le cas des autres classes mais cette diminution est moins flagrante que dans le cas des deux autres modèles et surtout celui basé uniquement sur l'information spectrale. Néanmoins, les valeurs de ces paramètres calculées pour ces classes peuvent être considérées relativement acceptables. Ces valeurs restent également intéressantes si nous les calculons en prenant en considération toutes les classes.

Afin de confirmer l'analogie entre l'analyse et l'interprétation faites pour la situation instantanée de précipitation du 03 janvier 2011 et celles effectuées pour une période de précipitations incluant cette situation instantanée, nous avons appliqué les trois modèles développés à une autre situation instantanée de précipitation appartenant à la même période. Les mêmes paramètres de vérification sont calculés pour les six classes et les résultats obtenus sont représentés dans les tableaux suivants (5.18, 5.19 et 5.20) :

	POD (%)	POFD (%)	FAR (%)	BIAS	CSI (%)	PC (%)
Classe(1)	78	15	29	1.2	66	91
Classe(2)	77	14	37	1.3	60	88
Classe(3)	65	18	39	0.6	52	85
Classe(4)	58	26	38	0.5	57	90
Classe(5)	58	29	38	0.6	57	89
Classe(6)	79	11	20	1.3	77	90

Tableau 4.15: Résultats de l'évaluation statistique pour la deuxième situation avec MLP-S

	POD (%)	POFD (%)	FAR (%)	BIAS	CSI (%)	PC (%)
Classe(1)	80	12	24	1.1	70	93
Classe(2)	79	11	29	0.9	69	92
Classe(3)	70	15	36	0.8	67	91
Classe(4)	66	24	34	0.7	66	93
Classe(5)	60	28	35	0.8	62	92
Classe(6)	81	8	19	1.2	80	95

Tableau 4.16: Résultats de l'évaluation statistique pour la deuxième situation avec MLP-ST1

	POD (%)	POFD (%)	FAR (%)	BIAS	CSI (%)	PC (%)
Classe(1)	83	8	22	0.9	74	96
Classe(2)	82	10	30	0.9	72	97
Classe(3)	74	12	32	0.9	70	95
Classe(4)	75	20	29	0.7	70	96
Classe(5)	63	27	33	0.8	67	94
Classe(6)	87	5	16	1.1	83	97

Tableau 4.17: Résultats de l'évaluation statistique pour la deuxième situation avec MLP-ST2

Les valeurs des ces trois tableaux indiquant les résultats obtenus après application des trois modèles de classification sur la deuxième situation de précipitations, nous confirment effectivement toutes les analyse et interprétations effectuées après application des mêmes modèles sur la première situation de précipitations que nous avons choisie pour une première évaluation de notre méthode. Nous constatons aussi, que dans l'ensemble, tous ces résultats concordent avec ceux délivrés par cette technique dans le cas de son application sur une période de précipitations incluant les deux situations précédentes. Ce qui nous permet de dire que cette méthode est bien adaptée à ce type de données.

Les histogrammes des paramètres statistiques calculés pour la situation instantanée d'une part, et pour toute la période choisie d'autre part, avec les trois modèles sont donnés ci-après, respectivement pour les modèles (MLP-S), (MLP-ST1) et (MLP-ST2) :




Figure 4.6 : Paramètres statistiques obtenus avec le modèle MLP-S pour une situation




Figure 4.7 : Paramètres statistiques obtenus avec le modèle MLP-ST1 pour une situation




Figure 4.8 : Paramètres statistiques obtenus avec le modèle MLP-ST2 pour une situation




Figure 4.9 : Paramètres statistiques obtenus avec le modèle MLP-S pour toute la période




Figure 4.10 : Paramètres statistiques obtenus avec le modèle MLP-ST1 pour toute la période




Figure 4.11 : Paramètres statistiques obtenus avec le modèle MLP-ST2 pour toute la période

Pour avoir une impression visuelle sur les performances de la méthode élaborée, nous allons présenter le résultat de la classification de l'image correspondant à la situation de précipitations que nous avons choisie et illustrée par la figure 4.12(a).

La figure 4.12(b) montre le résultat de la classification de cette image en plusieurs classes correspondant aux différentes intensités de précipitations obtenu par le premier modèle (MLP-S) et la figure 4.12(c) correspond au résultat de la classification la même image avec le modèle (MLP-ST2).




Figure 4.12: Résultats de classification de la scène du 03 Janvier 2011 à 14:00 UTC

En observant cette figure, nous pouvons dire qu'il existe une bonne concordance entre les images classifiées et les valeurs des paramètres statistiques correspondants, ce qui confirme ainsi l'analyse et l'interprétation faites auparavant.

Cependant, la première solution présente plusieurs imperfections notamment au niveau de l'affectation de chaque pixel à l'une des six classes fixées au départ. En effet, en plus des six classes identifiées correspondant aux différentes intensités de précipitations, nous remarquons l'existence d'une autre classe représentée par la couleur noire dans l'image classifiée et qui correspond aux pixels mal classés que le modèle (MLP-S) n'a pu affecter à aucune des six classes considérées. L'introduction de l'information texturale a permis de corriger ces imperfections et d'améliorer le résultat de la classification. Nous remarquons dans ce cas, que les classes sont mieux identifiées et le nombre de pixels mal classifiés a remarquablement diminués.

4.7.4. Comparaison de la technique élaborée avec la méthode PRI

Pour confirmer les performances de notre approche, nous avons appliqué à la même base de données, l'algorithme (PRI) basée sur les probabilités d'intensités de précipitation et qui donne souvent de bons résultats pour ce type d'applications ([Giannakos et Feidas 2013](#)). Comme dans le cas de la modélisation avec les réseaux de neurones que nous avons développés, la méthode (PRI) est appliquée d'abord avec les paramètres spectraux (PRI-S), puis avec une association des paramètres spectraux et texturaux (PRI-ST).

Le tableau 4.18 résume les valeurs des différents paramètres statistiques calculées par les quatre algorithmes (MLP-S, MLP-ST, PRI-S et PRI-ST) pour la même situation:

<i>Technique</i>	<i>POD (%)</i>	<i>POFD (%)</i>	<i>FAR (%)</i>	<i>BIAS</i>	<i>CSI (%)</i>	<i>PC (%)</i>
<i>PRI-S</i>	62	18	45	1.7	48	69
<i>PRI-ST</i>	69	14	38	1.5	59	98
<i>MLP-S</i>	78	11	32	1.3	65	91
<i>MLP-ST</i>	84	6	26	1.1	73	96
<i>Valeurs Optimales</i>	100	0	0	1	100	100

Tableau 4.18 : Résultats de comparaison entre les quatre techniques de classification

Ces valeurs montrent d'une part, que les modèles basés sur les réseaux de neurones (MLP) sont plus performants que les techniques basées sur la probabilité d'intensités de précipitations (PRI), et d'autre part, les techniques basées sur une combinaison entre les paramètres spectraux et texturaux (PRI-ST and MLP-ST) donnent de meilleurs résultats que ceux obtenus en n'utilisant que l'information spectrale (PRI-S and MLP-S). Aussi, même si les valeurs de ces paramètres calculées pour toutes les classes par les trois algorithmes (MLP-S, PRI-S, PRI-ST) sont acceptables, les meilleurs valeurs de ces paramètres, sont celles délivrées par le modèle (MLP-ST) basé sur une combinaison entre l'information spectrale et l'information texturale et plus particulièrement celle du second ordre.




Figure 4.13 : Paramètres statistiques obtenus avec les quatre techniques

4.8. Discussion :

Dans ce chapitre, nous avons présenté une nouvelle technique de classification permettant de séparer les nuages observés dans une image multispectrale en différentes classes selon leur contenu en eau. Trois modèles basés sur les réseaux de neurones ont été développés. Le premier modèle (MLP-S) délivre des résultats acceptables mais restent un peu loin de ceux escomptés car il présente quelques imperfections notamment au niveau des pixels mal classifiés. Le résultat de classification obtenu avec le deuxième modèle (MLP-ST1) pour le même jour et la même heure, montre que nous sommes, dans l'ensemble, en bon accord car nous avons une bonne analogie des formes des classes avec certaines améliorations. Par contre, nous pouvons constater quelques différences notamment au niveau des parties contenant les pixels mal classés dont le nombre a légèrement diminué. Cette

diminution peut résulter de la prise en compte de l'information texturale par l'intermédiaire des paramètres statistiques du premier ordre. Nous pouvons donc dire que, sur le principe, cette solution offre des améliorations par rapport au premier modèle, mais elle n'est toujours pas optimale car les résultats qu'elle délivre peuvent à leur tour être améliorés. Ceci nous a conduits à rechercher un autre type de paramètres statistiques d'ordre supérieur pour améliorer cette solution. C'est ainsi que nous avons choisi de remplacer les attributs statistiques du premier ordre par des attributs statistiques du deuxième ordre basés sur le calcul des matrices de cooccurrence pour développer le troisième modèle (MLP-ST2) permettant ainsi de corriger ces imperfections et d'améliorer d'une façon considérable le résultat final de la classification.

CONCLUSION ET PERSPECTIVES

La classification d'images représente une étape primordiale pour interpréter le contenu d'une scène donnée avant toute prise de décision. Ce travail est axé essentiellement sur la classification des images multispectrales caractérisées par une très grande richesse d'information spectrale particulièrement intéressante. Dans ce type d'images, les pixels sont considérés comme un simple tableau de mesures spectrales et souvent traités individuellement, sans tenir compte ni de leurs relations de voisinage ni des corrélations qu'elles peuvent représenter.

La principale contribution apportée dans le cadre de cette thèse, est l'introduction de deux nouvelles approches de classification tirant profit des deux principales informations, aussi bien spectrale que spatiale. La pertinence et l'efficacité de ces méthodes, reposent essentiellement sur le choix du nombre et du type paramètres à utiliser pour l'identification et la discrimination des différentes classes de l'image à traiter, mais aussi sur le choix de la région où elles ont été développées.

La première méthode (VMMRF) est fondée sur une modélisation par champs de Markov associée à une stratégie vectorielle des différentes composantes spectrales choisies. Appliquée aux images MSG, cette technique a permis d'identifier correctement les différentes classes correspondant aux différents types de sols, à la mer ainsi qu'aux différents types de nuages. Les résultats de la classification montrent la supériorité de cette approche comparativement à d'autres techniques usuelles publiées dans la littérature telles que celles basées sur une approche monospectrale.

La deuxième méthode est basée sur une implémentation avec les réseaux de neurones perceptrons multicouches (MLP). Elle permet une classification des nuages selon leur contenu en eau. Les étapes d'apprentissage et la validation de cette technique sont réalisées sur des bases de données constituées d'images couvrant le nord de l'Algérie et collectées simultanément par le satellite MSG et par le Radar Sétif. Les résultats obtenus montrent une meilleure performance de la technique basée sur une utilisation combinée de l'information spectrale et de l'information texturale notamment celle du second ordre (MLP-ST2).

Cependant, elle ne peut pas être extrapolée pour toutes les régions du globe ou à toutes les échelles du temps.

Une étude comparative a été effectuée entre les résultats des méthodes développées et ceux d'autres méthodes de classification conventionnelles. L'analyse qualitative de ces différents résultats montre que les algorithmes que nous avons proposés ont montré une bonne performance car ils ont réussi à discriminer toutes les classes avec moins de confusion.

Le travail effectué dans le cadre de cette thèse, ne prétend pas fournir une classification optimale, mais il ouvre une voie à de nouvelles recherches et explorations afin de répondre aux différentes questions soulevées et qui s'ouvrent comme autant de perspectives pour la poursuite de travaux futurs qui peuvent être engagés afin de compléter ces approches, les rendre plus performantes ou les adapter à de nouvelles problématiques.

Ainsi, les performances des deux méthodes implémentées sous leur forme actuelle peuvent être largement améliorées. Pour atteindre cet objectif, il serait intéressant:

- de développer un système permettant d'automatiser les différentes étapes,
- d'améliorer le critère du choix de la sélection des attributs les moins redondants,
- de tester un mélange d'attributs statistiques des différents ordres et types,
- d'étendre la période et la zone d'étude et d'incorporer d'autres types d'observations telles que les micro-ondes et radar issues de capteurs embarqués et de tester cette approche sur des images satellitaires provenant d'autres satellites tels que le satellite TRMM,
- de tester d'autres méthodes de classification.

Tous ces points offrent des possibilités d'études aboutissant à l'amélioration de tout ce que nous avons développé dans cette thèse et qui fera l'objet de nos futurs travaux de recherche.

Annexe A

Généralités sur la physique du rayonnement

Le traitement de l'imagerie satellitaire numérique utilise les propriétés du rayonnement électromagnétique pour analyser à distance la surface du sol, de l'océan ou l'atmosphère. La maîtrise de la physique élémentaire de ce rayonnement est indispensable pour toute interprétation des résultats obtenus.

A.1. Le rayonnement électromagnétique

Le rayonnement électromagnétique représente les différentes radiations émises par une source d'énergie (soleil, terre, océan, atmosphère, capteur...) sous forme d'ondes électromagnétiques. Il peut être aussi être considéré comme un déplacement de particules élémentaires représentant une quantité d'énergie (optique énergétique et quantique).

Une onde électromagnétique est une onde progressive et transversale qui comporte à la fois un champ électrique et un champ magnétique vibrant simultanément et oscillant à la même fréquence. Ces deux champs, perpendiculaires l'un par rapport à l'autre se propagent dans un milieu selon une direction orthogonale (figure A.1). La propagation de ces ondes s'effectue à une vitesse qui dépend du milieu considéré. Dans le vide, la vitesse de propagation est égale à 3.10^8 m.s^{-1} .




Figure 1.1 : Nature et propagation d'une onde électromagnétique

L'onde électromagnétique simple (monochromatique, plane) se caractérise par : sa période, sa fréquence, sa longueur d'onde, sa polarisation et son amplitude.

- **La période T** : c'est le temps au bout duquel le champ électrique ou magnétique retrouve sa valeur à partir d'un instant quelconque, c'est à dire effectué un cycle. L'unité est la seconde.
- **La fréquence**, désignée par la lettre ν : c'est le nombre de cycles par unité de temps. L'unité de fréquence est le Herz (Hz). Un Hz équivaut à un cycle par seconde. Les ondes utilisées en télédétection se caractérisent par des fréquences très élevées mesurées en multiples du Hz (kHz, MHz ou GHz).
- **La longueur d'onde (λ)** : c'est l'équivalent spatial de la période temporelle. En effet, la longueur d'onde est la plus courte distance séparant deux points de l'onde strictement identiques à un instant donné. Aussi, c'est la distance parcourue par l'onde au cours d'une période. Elle est exprimée par une unité de longueur, le mètre ou ses sous-multiples, en particulier: le micron ou micromètre: μm . $1\mu\text{m} = 10^{-6}\text{ m}$ et le nanomètre: nm. $1\text{nm} = 10^{-9}\text{ m}$.

A.2 Le spectre électromagnétique :

Le rayonnement électromagnétique, qu'il soit d'origine naturelle ou artificielle, existe pour une gamme très étendue de fréquences. La répartition des ondes électromagnétique en fonction de leur longueur d'onde constitue le spectre électromagnétique représenté par la figure suivante :




Figure A. 2 : Le spectre électromagnétique (Bonn et Rochon)

Parmi toutes ces fenêtres spectrales, trois sont principalement utilisées en télédétection spatiale à savoir : le visible, l'infrarouge et les micro-ondes.

Une partie très limitée de ce spectre, qui s'étend de 390 nm à 700 nm, constitue la lumière visible perceptible par l'œil humain. Une décomposition en fonctions des longueurs d'onde de la lumière visible (lumière blanche) permet de distinguer différentes compositions colorées. Ces lumières colorées varient du violet au rouge.

Les longueurs d'onde supérieures à $0.7\ \mu\text{m}$ et inférieures à $100\mu\text{m}$, non-perçues par l'œil humain, constituent le domaine infrarouge qui est relativement étendu car il couvre un intervalle de longueurs d'ondes dont la valeur $99.3\mu\text{m}$. Ce domaine est réparti sur quatre intervalles qui vont du proche infrarouge à l'infrarouge lointain, en passant par l'infrarouge moyen et le thermique.




Figure A.3: Le domaine des infrarouges

- ✓ le proche infrarouge : il est très utilisé en télédétection pour différencier les surfaces naturelles qui se caractérisent par une très forte réflectance à cette longueur d'onde, alors qu'elles réfléchissent peu le rayonnement dans le visible, et également pour étudier les surfaces continentales dans le but de distinguer les surfaces végétalisées des surfaces minérales.
- ✓ l'infrarouge moyen : il est très utilisé en foresterie et en agriculture pour cartographier les couverts végétaux. Il est utilisé également dans l'étude de la teneur en eau des surfaces naturelles. Seules quelques fenêtres atmosphériques centrées sur les longueurs d'onde $2,5\mu\text{m}$, $3,5\mu\text{m}$ et $5\mu\text{m}$ permettent la transmission du rayonnement. Cela est dû au fait que l'atmosphère est en grande partie opaque aux rayonnements du moyen infrarouge qui sont absorbés par la vapeur d'eau.
- ✓ L'infrarouge thermique : dans les domaines du visible et du proche infrarouge, une partie du rayonnement qui parvient à la surface de la terre est absorbée par les objets, puis réémise sous forme de chaleur à une plus grande longueur d'onde. Dans le domaine de l'infrarouge thermique, les capteurs satellitaires mesurent la température apparente des objets et le rayonnement dépend des propriétés d'émissivité des surfaces.
- ✓ L'infrarouge lointain : il n'est utilisé ni pour l'observation de la terre, ni pour l'étude de l'atmosphère. Il est spécialement utilisé pour étudier la formation des galaxies et des étoiles. Les détecteurs, appelés bolomètres utilisent cette gamme de longueurs d'onde pour mesurer l'intensité du rayonnement infrarouge émis par les corps célestes. Le capteur SEVIRI de MSG ne comporte pas de bandes spectrales dans ce domaine.

Dans le domaine des hyperfréquences (1cm à 1m), les longueurs d'onde centimétriques sont grandes par rapport aux ondes visibles et infrarouges. Cela confère aux hyperfréquences des propriétés particulières et notamment la possibilité d'observer la surface de la Terre par tous les temps, de jour comme de nuit. L'atmosphère est en effet quasiment transparente à ces longueurs d'onde qui traversent donc sans problème les couches nuageuses. Les capteurs radars et les radiomètres à micro-ondes passives sont les capteurs utilisés dans ce domaine, notamment en océanographie pour l'étude des glaces de mer et la détection des nappes d'hydrocarbures.

A.3. Les différentes sources du rayonnement électromagnétique

L'observation de la Terre par les satellites implique nécessairement une source d'énergie. Il existe différentes sources du rayonnement qui peuvent varier en fonction du domaine du spectre électromagnétique. En télédétection, trois sources d'énergie peuvent être utilisées: le soleil, la surface terrestre ou le capteur lui-même.

Le soleil qui illumine la surface terrestre est la source la plus commune et la plus utilisée. Le capteur satellitaire mesure et enregistre la partie du rayonnement réfléchi par une surface. Ce processus illustre la télédétection optique, dans les domaines du visible et du proche infrarouge.

La surface terrestre peut également émettre un rayonnement qui peut être aussi capté et enregistré par les capteurs satellitaires. Cette situation correspond à la télédétection dans le thermique ou dans le domaine des micro-ondes passives.

Le capteur, notamment satellitaire, peut être aussi considéré comme une source d'énergie qui permet d'émettre grâce à une antenne, un rayonnement vers la surface terrestre, puis d'enregistrer la partie rétrodiffusée de ce rayonnement. Ce processus est celui de la télédétection active dans le domaine des hyperfréquences.

Le rayonnement ultraviolet, visible ou infrarouge est émis par les corps, objets ou surfaces selon leur température. Il peut s'agir du rayonnement solaire pour les U.V., le visible et le proche infrarouge, ou du rayonnement terrestre pour l'infrarouge thermique.

Le soleil peut être aussi une source pour le rayonnement ultraviolet. Les rayonnements de très courte longueur d'onde à savoir les rayons gamma et les rayons X sont produits par les restructurations des noyaux des atomes (radioactivité). Quand aux rayonnements de grande longueur d'onde, ils sont produits par des oscillations électroniques (antennes).

A.4. La mesure du rayonnement

Le rayonnement électromagnétique réfléchi ou émis par la surface terrestre, les océans ou l'atmosphère, est mesuré par le capteur satellitaire lorsque celui-ci lui parvient. La mesure du rayonnement se fait essentiellement à partir de l'énergie transportée par ce rayonnement. La grandeur radiométrique mesurée et enregistrée au niveau du capteur satellitaire est donc un flux énergétique qui représente ce qu'on appelle une luminance qui s'exprime en $\text{W.m}^{-2}.\text{sr}^{-1}.\mu\text{m}^{-1}$.

Les luminances permettent donc de différencier les surfaces sur une image. En revanche, si l'on veut étudier l'évolution d'une surface (couverture végétale par exemple) au cours du temps, on ne pourra pas comparer les luminances d'une image à une autre, car elles dépendent de l'éclairement reçu par la surface. Il faut donc convertir les luminances en une grandeur indépendante de l'éclairement incident, la réflectance qui est le rapport entre l'énergie réfléchie par une surface et l'énergie incidente reçue par cette même surface pour une longueur d'onde donnée. C'est une grandeur sans unité comprise entre 0 et 1 ou souvent exprimée en pourcentage.

En télédétection, les radiomètres sont généralement les capteurs les plus utilisés pour mesurer et enregistrer un flux d'énergie ou flux radiatifs (ϕ), en provenance d'une surface. Mesurer un rayonnement revient donc à calculer la quantité d'énergie émise, transportée ou reçue par unité de temps. L'intensité de cette énergie dépend de :

- L'étendue de la bande spectrale à laquelle est sensible le capteur
- L'étendue de la surface terrestre qui émet ou réfléchit.
- L'ouverture du champ de vision du capteur par rapport à l'émission ou à la réflexion de la surface qui s'effectue dans toutes les directions.

A.5. Le rayonnement et l'atmosphère

Lors de son trajet depuis la source (le soleil) vers la cible (surface terrestre), puis de la cible vers le capteur, le rayonnement électromagnétique subit des interactions avec les molécules gazeuses et les particules (aérosols, gouttelettes d'eau, poussières) présentes dans l'atmosphère. Deux phénomènes essentiels se produisent : l'absorption et la diffusion atmosphériques (figure A.4). Les molécules gazeuses et particules présentes dans l'atmosphère vont provoquer un blocage et/ou une déviation du rayonnement, diminuant ainsi l'énergie transportée par le rayonnement électromagnétique.




Figure A.4 : Absorption par l'ozone et diffusion atmosphérique du rayonnement électromagnétique, lors de sa traversée de l'atmosphère.

Lorsque l'on s'intéresse à l'observation spatiale de la surface terrestre, il est impératif de prendre en compte les interactions rayonnement-atmosphère puisque le signal qui parvient au capteur satellitaire est perturbé par la traversée atmosphérique. A part dans le domaine de la météorologie spatiale où l'on cherche à mesurer la composition et à comprendre les propriétés de l'atmosphère, cet effet perturbateur de l'atmosphère doit être pris en considération dans l'interprétation du signal mesuré par le satellite.

A.6. Le rayonnement et la matière

Lorsqu'une matière solide, liquide ou gazeuse est soumise à un rayonnement émis par une source extérieure, une partie de ce rayonnement est absorbée et transformé en chaleur selon le principe de la conversion de l'énergie radiative en énergie thermique. L'autre partie est soit réfléchi par l'objet en question, soit transmise à travers le corps avec éventuellement un changement de direction de la propagation qui est une réfraction (figure A.5). La propagation ne se fait donc entièrement et sans perte que dans le vide. Ainsi, on peut dire qu'un corps quelconque se caractérise par trois coefficients qui expriment la quantité de l'énergie radiative absorbée, réfléchi ou transmise : un coefficient d'absorption (α), un coefficient de réflexion (ρ) et un coefficient de transmission (τ), qui expriment respectivement la part d'énergie absorbée, réfléchi et transmise. Selon le principe de conservation de l'énergie, ces trois coefficients ont des valeurs qui varient entre 0 et 1 et leur somme est toujours égale à 1:

$$\alpha + \rho + \tau = 1 \quad (1.2)$$




Figure A.5 : Réflexion, transmission et absorption du rayonnement

Théoriquement, un corps noir est un corps, à la fois opaque et non-réfléchissant, dont la propriété est d'absorber la totalité des rayonnements qu'il reçoit. ($\alpha=1$, $\rho = \tau = 0$)

Les corps blancs sont des corps qui réfléchissent totalement l'énergie qu'ils reçoivent ($\alpha=0$, $\rho=1$) et les corps gris appelés corps naturels se caractérisent par : $0 < \alpha < 1$ et $0 < \rho < 1$.

A.7. La signature spectrale :

Chaque objet ou chaque surface possède une réponse spectrale bien précise à une longueur d'onde donnée. L'ensemble des réponses spectrales à différentes longueurs d'onde constitue ce que l'on appelle la signature spectrale d'une surface. Chaque type de surface peut ainsi être caractérisé et identifié sur une image. Chaque surface possède ainsi une signature spectrale - quantité d'énergie émise ou réfléchie en fonction de la longueur d'onde - qui lui est propre et qui permettra son identification sur les images satellitaires. La figure A.6 présente la signature spectrale des principales surfaces naturelles.




Figure A.6 : Signatures spectrales des surfaces naturelles dans le domaine du visible, du proche infrarouge et de l'infrarouge moyen

Annexe B

Notions de base sur les champs de Markov et les réseaux de neurones

B.1. Les champs de Markov

B.1.1. Définition d'un système de voisinage et cliques associées

Dans le domaine d'analyse d'images, et plus particulièrement dans notre cas, nous représentons l'image par une grille S rectangulaire bidimensionnelle de taille $m \times n$. Chaque site (pixel) s de la grille peut être désigné:

- Soit par ses coordonnées : $S = \{(i, j), 0 \leq i \leq m-1, 0 \leq j \leq n-1\}$
- Soit par son numéro d'ordre : $S = \{s_1, s_2, \dots, s_M\}$, où : $M = n \times m$ est le cardinal de S .

La définition d'un système de voisinage en termes de "plus proches voisins" sur la grille S permet sa structuration sous la forme d'un graphe non orienté $G = [S, V(S)]$, où le système de voisinage $V(S) = \{V_s(S); s \in S\}$ possède les propriétés suivantes :

$$\begin{aligned} \text{(i)} \quad & \forall s \in S, s \notin V_s(S) \\ \text{(ii)} \quad & \forall \{s, t\} \subset S, s \in V_t(S) \Leftrightarrow t \in V_s(S) \end{aligned} \quad (\text{B.1})$$

A partir de cette définition, nous déduire les cliques associées à un voisinage. Une clique (c) est un ensemble(C) de sites tous voisins les uns des autres tels que :

$$\begin{cases} \exists s \in S : c = \{s\} \\ \text{ou} \\ \forall \{s, t\} \subset c, t \in V_s(S) \end{cases} \quad (\text{B.2})$$

L'ensemble C comporte donc, les singletons et les parties de S dont les éléments sont voisins deux à deux.

Le nombre de cliques dépend du système de voisinage utilisé. Les systèmes de voisinage les plus couramment utilisés sont ceux d'ordre 1 et 2. Pour un système de voisinage de premier ordre avec 4 types de connexité, nous avons deux types de cliques. Pour un système de voisinage de deuxième ordre (8 connexités), nous pouvons avoir des cliques d'ordre 2, 3, 4. Ces types de cliques utilisés sont illustrés dans la figure B.1.




Figure B.1 : Voisinage bidimensionnel d'ordre 1 et 2 et les cliques associées.

B.2.2. Champs de Markov et distributions de Gibbs

Étant donné un ensemble S fini de sites (pixels), on s'intéresse à des collections $\{x_s; s \in S\}$ de variables indexée s par les éléments de S et prenant leurs valeurs respectives dans des ensembles Λ_s supposés au plus dénombrables, souvent confondues avec un unique ensemble Λ ($\Lambda = \{1, \dots, k\}$ dans le cas de la classification d'image ; k étant le nombre total de classes). On notera par $E = \prod_{s \in S} \Lambda$ (l'espace des configurations (fini dans notre cas)).

Soit P une mesure de probabilité définie sur $(E, P(E))$ où $P(E)$ est l'ensemble de toutes les parties de E ; alors le triplet $X = (E, P(E), P)$ définit un champ aléatoire discret sur S . Le champ X est généralement assimilé au vecteur aléatoire $\{X_s; s \in S\}$ indexé par les éléments de S . Ainsi la loi de probabilité P_X de X est confondue avec la mesure P .

➤ Champs de Markov

Un champ aléatoire, $X = \{X_s, s \in S\}$ est un champ markovien sur un graphe $G = [S, V(S)]$ si et seulement si il vérifie :

$$\forall \omega \in E, P_X(\omega) > 0 \quad \text{contrainte de positivité}$$

$$\forall s \in S, \forall \omega \in E$$

$$P_X(X_s = \omega_s / X_t = \omega_t, t \in S, t \neq s) = P_X(X_s = \omega_s / X_t = \omega_t, t \in \Gamma_s(S)) \quad (\text{B.3})$$

On dit alors que X est un champ aléatoire de Markov (MRF) sur S relativement au système de voisinage $V(S)$ ou simplement sur le graphe $G = [S, V(S)]$. Il est clair que l'intérêt porté aux champs de Markov réside essentiellement dans la notion de localité (un voisinage de faible taille). Ainsi

dans la pratique, l'introduction des champs markoviens permet la modélisation d'ensembles de variables aléatoires dont les interactions mutuelles résultent uniquement de la combinaison d'interactions locales.

➤ Champs de Gibbs

Un champ aléatoire $X = \{X_s, s \in S\}$ est un champ de Gibbs sur S relativement au système de voisinage $V(S)$ si et seulement si P_x est une distribution de Gibbs donné par :

$$\forall \omega \in E, P_x(\omega) = \frac{1}{Z} \exp \left\{ -\frac{U(\omega)}{T} \right\}, \quad (B.4)$$

$$\text{Avec : } Z = \sum_{x \in E} \exp \left\{ -\frac{U(\omega)}{T} \right\}. \quad (B.5)$$

Z est une constante de normalisation appelée fonction de partition.

On dit aussi que X est un champ aléatoire de Gibbs (GRF) sur le graphe $[S, V(S)]$.

La fonction :

$$U(\omega) = \sum_{c \in C} V_c(\omega) \quad (B.6)$$

définie sur E , est la fonction d'énergie du champ de Gibbs X et $\{V_c \in C\}$ est une famille de potentiels sur les cliques du graphe $[S, \Gamma(S)]$.

➤ Théorème de Hammersley-Clifford

Un champ de Markov est caractérisé par sa propriété locale ("markovienité") alors qu'un champ de Gibbs par sa propriété globale (distribution de Gibbs). Le théorème Hammersley-Clifford ([Besag, 1974](#)) établit l'équivalence entre champs de Gibbs et champs de Markov vérifiant la propriété de positivité. Son énoncé est le suivant :

« Un champ aléatoire sur l'ensemble fini de sites S est un champ de Markov sur le graphe $G=[S, \Gamma(S)]$ vérifiant la propriété de positivité si et seulement si c'est un champ de Gibbs sur G . »

D'un point de vue pratique, la spécification des propriétés locales d'un champ de Markov via la définition des fonctions potentielles des cliques, traduisant un certain *a priori* ou une certaine préférence concernant les interactions locales, se traduit de façon équivalente par la caractérisation globale du modèle probabiliste.

B.2. Les réseaux de neurones

B.2.1. Le neurone biologique

Le neurone est considéré comme étant le processeur élémentaire du cerveau. Chaque neurone traite l'information qui lui parvient localement, puis la transmet aux autres neurones qui lui sont connectés. Ces cellules sont capables d'apprendre par changement d'intensité de leurs connexions avec d'autres cellules, de détruire ou même de créer de nouvelles connexions. Elles peuvent aussi changer leurs règles de traitement de l'information. Ce processus de changement appelé « apprentissage », joue un rôle fondamental dans le comportement du neurone ([Haykin, 1994](#)).

Un neurone est composé des quatre parties suivantes:

- *Corps cellulaire* : considéré comme noyau du neurone.
- *Dendrites*: qui représentent les récepteurs principaux de neurone.
- *Axone* : c'est la fibre nerveuse qui transporte les signaux émis par le neurone.
- *Synapse*: essentielle dans le fonctionnement du système nerveux, elle représente la connexion entre la dendrite et l'axone de deux neurones qui communique l'information, en la pondérant par un poids synaptique, à un autre neurone.

Chaque neurone réalise une somme pondérée de ses entrées qui est comparée à un seuil, s'il est dépassé, le neurone devient excité. L'information contenue dans le cerveau est représentée par les poids donnés aux entrées de chaque neurone. Ce système possède une propriété de tolérance aux fautes à cause du grand nombre de neurones et de leurs interconnexions.

B.2.2. Modélisation pratique d'un neurone artificiel

Dans la pratique, un neurone peut être défini par les trois éléments importants suivants :

- ***La fonction d'entrée totale $h(U)$*** : qui définit le prétraitement effectué sur les entrées. Elle peut être une combinaison booléenne ou linéaire des entrées.
- ***La fonction d'activation (ou état) du neurone***: appelée aussi *fonction de seuillage*, ou encore *fonction de transfert* définit son état interne en fonction de son entrée totale. Elle sert à introduire une non-linéarité dans le fonctionnement du neurone. Cette fonction présente généralement trois intervalles :
 - en dessous du seuil, le neurone est non-actif (souvent dans ce cas, sa sortie vaut 0 ou -1) ;
 - aux alentours du seuil, une phase de transition ;
 - au-dessus du seuil, le neurone est actif (souvent dans ce cas, sa sortie vaut 1).

La fonction d'activation $f(E)$ prend généralement les formes suivantes :

- ✚ Une fonction binaire à seuil.
- ✚ Une fonction linéaire par morceaux.
- ✚ Une fonction sigmoïde.

- ✓ **La fonction de sortie:** qui calcule la sortie du neurone en fonction de son état d'activation. Elle est souvent considérée comme la fonction identité.

Les équations décrivant le comportement des neurones artificiels n'introduisent pas la notion de temps. En effet, c'est le cas pour la plupart des modèles actuels de réseaux de neurones, nous avons affaire à des modèles à temps discret, synchrone, dont le comportement des composants ne varie pas dans le temps (Haykin, 1994).

B.2.3. Fonctionnement d'un réseau de neurones

Avant d'aborder le comportement collectif d'un ensemble de neurones, nous allons présenter le perceptron (un seul neurone) en phase d'utilisation. L'apprentissage ayant été réalisé, les poids sont fixes.

Le neurone de la figure 3.4 réalise une simple somme pondérée de ses entrées, compare une valeur de seuil et fournit une réponse binaire en sortie. Par exemple, on peut interpréter sa décision comme classe 1 si la valeur de x est $+1$ et classe 2 si la valeur de x est -2 . Les connexions des deux entrées $e1$ et $e2$ au neurone sont pondérées par les poids $w1$ et $w2$. La valeur de sortie du neurone est notée x . Elle est obtenue après une somme pondérée des entrées (a) et comparaison à une valeur de seuil S (Haykin, 1994).

Soit s_i la sortie du neurone i . Le neurone j est connecté aux N neurones de la couche précédente et reçoit leur sorties via les liaisons pondérées par les poids w_{ji} . Le neurone j reçoit donc le signal d'activation a_j :

$$a_j = \sum_{i=1}^N w_{ji} s_i + w_{j0} \quad (3.3)$$

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 3.4).

La sortie du neurone j est régie par la fonction de transfert f_j appelée fonction d'activation. Cette dernière doit être non-linéaire pour que le réseau de neurones puisse résoudre des problèmes non-linéaires. Parmi les fonctions de transfert, la plus généralement utilisée est la fonction sigmoïde

défini par l'équation suivante :

$$f: \mathbb{R} \rightarrow [0 \ 1] : f(a_i) = \frac{1}{1+e^{-a_i}} \quad (3.4)$$




Figure 3.4 Structure d'un neurone caché ou de sortie

B.2.4. Nombre de neurones de chaque couche

Un réseau de neurones réalise une association non linéaire entre ses entrées et ses sorties. Le nombre de neurones de la couche d'entrée est égal au nombre d'attributs choisis, le nombre de neurones de la couche de sortie correspond au nombre de classes recherchées et le nombre de neurones de la couche cachée déterminé pendant la phase d'apprentissage. Les entrées sont généralement normalisées de telle sorte à avoir des valeurs comprises entre 0 et 1.

L'un des inconvénients des réseaux de neurones à couches est la difficulté à trouver un lien entre le type et la complexité du problème à traiter d'une part, et le nombre de couches cachées ainsi que le nombre de neurones par couche d'autre part. Il n'existe pas d'outils théoriques fiables pour trouver cette relation. Néanmoins, des formules empiriques peuvent être utilisées pour déterminer le nombre maximal de neurones (N_c) dans une couche cachée d'un réseau de neurones à (N_e) entrées, telle que l'équation suivante:

$$N_c \leq 2 \cdot N_e + 2 \quad (3.5)$$

Mais dans la plus part des cas, l'utilisateur doit effectuer un grand nombre d'expériences afin de déterminer le nombre de neurones dans la couche cachée. L'exemple le plus fréquent, consiste à faire varier la taille du réseau puis à effectuer un apprentissage complet pour chaque taille et à la fin on opte pour la structure qui amène aux meilleurs résultats.

B.2.5. L'apprentissage

L'apprentissage est la propriété la plus importante des réseaux de neurones. C'est une phase du développement du réseau durant laquelle le comportement de ce dernier est modifié jusqu'à l'obtention du comportement désiré et qui fait appel à des exemples de comportement.

Dans la plupart des algorithmes utilisés actuellement, les variables modifiées pendant

l'apprentissage neuronal sont les poids des connexions. L'apprentissage consiste donc à modifier les poids du réseau afin d'accorder la réponse du réseau aux exemples et à l'expérience. Deux phases peuvent toujours être distinguées : une phase d'apprentissage ou de remise à jour du comportement et une phase d'utilisation. Cette technique permet au réseau de conserver un comportement adapté malgré les fluctuations dans les données d'entrées.

B.2.5.1. Caractéristiques de l'algorithme d'apprentissage supervisé

La conception d'un réseau de neurones est réalisée selon les tâches à effectuer définies par l'utilisateur par une base de données dont il dispose appelée « ensemble d'apprentissage D ». Chaque élément de cet ensemble qui se présente sous forme d'un couple (x, y^*) entre une valeur d'entrée du réseau (x) et la valeur désirée (y^*) correspondante pour les sorties des neurones de sortie, est appelé « exemple d'apprentissage ».

Les tâches que doit remplir le réseau permettent donc de fixer son architecture, la structure de ses connexions ainsi que les fonctions d'activation.

Après avoir choisi l'architecture du réseau de neurones à utiliser, une étape d'apprentissage doit être effectuée afin de déterminer les valeurs des poids qui permettent à la sortie du réseau de neurones d'être aussi proche que possible du résultat recherché. Les valeurs des poids synaptiques sont, généralement déterminés par un algorithme qui met en œuvre l'ensemble d'apprentissage.

Cette phase d'apprentissage consiste en la minimisation d'une fonction de coût calculée à partir des exemples de données choisies comme base d'apprentissage et des sorties du réseau de neurones. Cette minimisation se fait souvent par une méthode basée sur l'algorithme de descente du gradient.

B.2.5.2. La méthode du gradient

La plus part des méthodes d'optimisation non linéaires sont basées sur la même stratégie. Un processus itératif est utilisé pour tenter d'optimiser la fonction (E). Cette optimisation implique deux étapes à chaque itération ([Haykin, 1994](#)). L'algorithme de la rétro propagation du gradient est très connu et plus utilisé dans les applications des réseaux de neurones. Un exemple d'apprentissage est retiré et une nouvelle estimation est calculée à chaque itération. Il est réalisé en deux phases :

- ✚ **L'étape de propagation:** dans laquelle un élément de l'ensemble d'apprentissage (D) est introduit à travers la couche d'entrée à chaque itération. L'évaluation des sorties du réseau se fait donc couche par couche, de l'entrée du réseau vers sa sortie.

✚ **L'étape de rétro propagation:** cette étape est similaire à la précédente sauf que les calculs, dans ce cas, s'effectuent dans le sens inverse. A la sortie du réseau, le critère de performance (J) est formé en fonction de la sortie réelle du système et sa valeur désirée. Ensuite, le gradient de (J) est évalué par rapport aux différents poids en allant de la couche de sortie vers la couche d'entrée.

B.2.5.3. Calcul du gradient

La fonction de coût la plus généralement utilisée est celle de l'erreur quadratique sur la base d'apprentissage dont le principe est de minimiser la somme des carrés des erreurs entre la sortie désirée (d_k) du réseau et la valeur réelle (ou calculée) de la sortie (O_k) de chaque neurone k . Cette fonction est définie par la relation suivante:

$$E = \frac{1}{2} \sum_k (d_k - O_k)^2 \quad (3.6)$$

Dans le cas d'un réseau de neurones à trois couches composé de (m) neurones en entrée, de (n) neurones cachés et de (p) neurones de sortie notés respectivement i , j et k .




Figure 3.5 : Schéma d'un réseau de neurones à 3 couches

Pour chaque neurone (j) de la couche cachée, nous pouvons écrire les relations suivantes :

$$a_j \leftarrow \sum_{i=0}^m x_i w_{ji} \quad ; \text{ avec } x_0 = 1 \text{ (Biais)} \quad (3.7)$$

$$y_j \leftarrow \frac{1}{1+e^{-a_j}} \quad (3.8)$$

et pour chaque neurone (k) de la couche de sortie, nous pouvons écrire aussi :

$$a_k \leftarrow \sum_{j=0}^n y_j w_{kj} \quad ; \text{ avec } y_0 = 1 \text{ (Biais)} \quad (3.9)$$

$$O_k \leftarrow \frac{1}{1+e^{-a_k}} \quad (3.10)$$

Le principe de l'algorithme de rétropropagation par descente de gradient illustré par la figure 3.6, consiste donc à rechercher le minimum de la fonction (E) dans l'espace des poids qui se fait par annulation des dérivées partielles.

Nous aurons donc:
$$\vec{w} \leftarrow \vec{w} + \Delta \vec{w} \quad (3.11)$$

Comme $\Delta \vec{w} = -\eta \nabla E[\vec{w}]$ avec η est le pas de descente ou d'apprentissage et $\nabla E[\vec{w}]$ est le gradient de l'erreur E , la relation précédente devient donc :

$$\vec{w} \leftarrow \vec{w} - \eta \nabla E[\vec{w}] \quad (3.12)$$




Figure 3.6: Principe de la descente de gradient

➤ Pour la couche de sortie nous pouvons écrire:

$$\frac{\partial E}{\partial w_{kj}} = \frac{\partial E}{\partial o_k} \cdot \frac{\partial o_k}{\partial a_k} \cdot \frac{\partial a_k}{\partial w_{kj}} = \delta_k y_j \quad (3.13)$$

$$\text{Avec } \delta_k = \frac{\partial E}{\partial o_k} \cdot \frac{\partial o_k}{\partial a_k} = -O_k(1 - O_k)(d_k - O_k) \quad (3.14)$$

$$\text{d'où : } \Delta w_{kj} = -\eta \frac{\partial E}{\partial w_{kj}} = -\eta \delta_k y_j \quad (3.15)$$

➤ Pour la couche cachée nous avons :

$$\frac{\partial E}{\partial w_{ji}} = \frac{\partial E}{\partial y_j} \cdot \frac{\partial y_j}{\partial a_j} \cdot \frac{\partial a_j}{\partial w_{ji}} = \delta_j x_i \quad (3.16)$$

$$\text{avec: } \delta_j = \frac{\partial E}{\partial y_j} \cdot \frac{\partial y_j}{\partial a_j} \quad (3.17)$$

$$\text{et } \frac{\partial E}{\partial y_j} = \frac{\partial E}{\partial a_k} \cdot \frac{\partial a_k}{\partial y_j} = \sum_{k=0}^p \delta_k w_{kj} \quad (3.18)$$

A partir de la propriété de la fonction sigmoïde nous avons :

$$\frac{\partial y_j}{\partial a_j} = y_j (1 - y_j) \quad (3.19)$$

$$\text{d'où : } \delta_j = y_j (1 - y_j) \sum_{k=0}^p \delta_k w_{kj} \quad (3.20)$$

$$\text{et } \Delta w_{ji} = -\eta \frac{\partial E}{\partial w_{ji}} = -\eta \delta_j x_i \quad (3.21)$$

B.2.5.4. Algorithme de rétropropagation du gradient

L'algorithme de rétropropagation avec minimisation du gradient d'erreur utilisé pour l'apprentissage du réseau de neurone MLP (Caloz et Collet, 2001) est décrit par ces étapes :

1. Initialiser les poids du réseau.

2. Injecter une observation (exemple) de la base de données sous forme de vecteur de caractéristiques à l'entrée du réseau, ensuite calculer sa valeur d'activation et sa fonction d'activation à l'aide des équations suivantes :

$$a_i = \sum_j w_{ij} o_j \quad (3.22)$$

$$f(a_i) = \frac{1}{1+e^{-a_i}} \quad (3.23)$$

3. Calculer δ_k et Δw_{kj} pour chaque neurone de sortie k , selon les formules suivantes :

$$\delta_k \leftarrow -O_k(1 - O_k)(d_k - O_k) \quad (3.24)$$

$$\Delta w_{kj}(t) = -\eta \delta_k y_j \quad (3.25)$$

4. Calculer δ_j et Δw_{ji} pour chaque neurone caché j selon les formules suivantes :

$$\delta_j = y_j (1 - y_j) \sum_{k=0}^p \delta_k w_{kj} \quad (3.26)$$

$$\Delta w_{ji}(t) = -\eta x_i \delta_j \quad (3.27)$$

5. Ajuster les poids w_{kj} et w_{ji} à l'instant t de la façon suivante :

$$w_{kj}(t) = \Delta w_{kj}(t - 1) + \Delta w_{kj}(t) \quad (3.28)$$

$$w_{ji}(t) = \Delta w_{ji}(t - 1) + \Delta w_{ji}(t) \quad (3.29)$$

6. Répéter les étapes 2 à 5 pour l'ensemble des exemples (observations) de la base d'apprentissage jusqu'à ce que le critère d'arrêt soit atteint.

La convergence du réseau de neurones est liée directement à la valeur de η . Elle est trop lente si la valeur de η est trop faible. Par contre, lorsque la valeur de η est trop élevée, les poids oscillent et par conséquent ne se stabilisent pas. L'idéal est de commencer avec une grande valeur de η , puis on diminue progressivement jusqu'à convergence.

Un coefficient α appelé (Inertie ou Momentum) dont la valeur est comprise entre (0.1) et (0.8), peut être ajouté dans le calcul de Δw pour prévenir les oscillations, augmenter la vitesse de convergence et empêcher la convergence vers un minimum local. L'expression de Δw à l'instant t est donnée par l'équation suivante :

$$\Delta w_{ji}(t) = -\eta \frac{\partial E}{\partial w} + \alpha \Delta w_{ji}(t - 1) \quad (3.30)$$

La valeur typique de (α) est égale à (0.6).

B.2.5.5. Choix des critères d'arrêts

A chaque itération (t), l'algorithme de rétropropagation du gradient est répété et le réseau converge si pour tous les exemples considérés, le coût est inférieur au seuil choisi. L'utilisation seule de ce critère, peut rendre la phase d'apprentissage très lente avant de converger. Pour éviter ce problème, on peut faire appel à d'autres critères d'arrêt comme:

- ✓ fixer un nombre maximum de périodes d'apprentissage qui représente le nombre de pas de l'algorithme;
- ✓ choisir une petite valeur comprise entre 0,1% et 1% de la variation absolue du coût (E) entre les périodes t et $t+1$. ([Haykin, 1994](#)). La valeur 0,1% est la plus utilisée;
- ✓ la norme du vecteur gradient qui doit être inférieure à un gradient seuil (ϵ) suffisamment petit (critère hybride de Kramer et Sangiovanni-Vincentelli (1989));
- ✓ utiliser le critère de la généralisation ([Haykin, 1994](#)) qui consiste à tester le réseau sur de nouvelles observations ne faisant pas partie de l'ensemble d'apprentissage après chaque période d'apprentissage.

En pratique, le choix d'un ou de plusieurs critères d'arrêt de l'apprentissage dépend de la nature du problème à résoudre ainsi qu'aux analyses envisagées à effectuer pour atteindre l'objectif visé.

Annexe C

Les attributs statistiques

Dans la partie suivante, nous allons décrire les estimateurs statistiques les plus fréquemment utilisés pour caractériser la texture d'une image et plus particulièrement ceux utilisés dans le cadre de notre étude. Une étude exhaustive des différentes approches d'analyse de texture en traitement d'images est donnée dans plusieurs ouvrages tels que celui de (Cocquerez et Philipp 1995).

C.1. Les attributs statistiques du premier ordre

Le calcul des attributs statistiques du premier ordre se fait à partir de l'histogramme des niveaux de gris dans le voisinage immédiat de chaque pixel, représenté par une fenêtre centrée sur chaque pixel. L'histogramme obtenu représente donc la fréquence d'apparition des niveaux de gris dans la fenêtre d'analyse de l'image.

Pour tout ce qui suit, on retient les notations suivantes :

- i : le niveau de gris du pixel dans la fenêtre d'analyse ;
- $h(i)$: l'histogramme du niveau de gris i dans cette fenêtre ;
- N : le nombre total de pixels dans cette fenêtre ;
- Ng : le nombre total de niveaux de gris dans la fenêtre d'analyse.

Les attributs suivants sont les attributs de textures du premier ordre les plus connus et les plus utilisés, qu'on peut extraire à partir de l'histogramme $h(i)$:

➤ Moyenne

Elle correspond au moment d'ordre 1 qui donne la valeur moyenne du niveau de gris de la fenêtre d'analyse dans une image. Elle permet de caractériser l'intensité lumineuse de l'image. Plus cette valeur moyenne est faible et plus l'image est sombre et ; et inversement. Elle est donnée par la formule suivante :

$$m = \frac{1}{N} \sum_{i=0}^{Ng} ih(i)$$

➤ Variance

Elle correspond au moment d'ordre 2 et mesure la dispersion des niveaux de gris autour de la valeur moyenne. Une faible variance indique que ces valeurs sont peu dispersées autour de la moyenne (homogénéité), et inversement (hétérogénéité). Elle est donnée par la formule suivante :

$$\sigma^2 = \frac{1}{N} \sum_{i=0}^{Ng} (i - m)^2 h(i)$$

➤ Coefficient de variation

➤ Les valeurs de la moyenne et de la variance ne permettent pas toujours de faire une discrimination suffisante. Le Coefficient de variation est le rapport entre ces deux quantités dont la valeur permet de mesurer l'ampleur de la variation des niveaux de gris. Elle est décrite par la relation suivante :

$$cv = \frac{\sigma}{m}$$

➤ Skewness

Il correspond au moment d'ordre 3 centré autour de la moyenne. Sa valeur caractérise la dissymétrie/asymétrie de l'histogramme d'une image. Ce paramètre mesure donc la déviation de la distribution des niveaux de gris par rapport à une distribution symétrique. Pour une déviation vers les valeurs élevées, le skewness est positif ; et inversement, il est négatif pour une déviation vers les valeurs basses. Il est donné par l'équation suivante :

$$Sk = \frac{1}{N\sigma^2} \sum_{i=0}^{Ng} (i - m)^3 h(i)$$

➤ Kurtosis

Il correspond au moment d'ordre 4 centré autour de la moyenne dont la valeur caractérise l'allongement/l'aplatissement de l'histogramme d'une image. Ce paramètre donne une indication sur la forme du sommet de l'histogramme : plus le kurtosis est faible et plus le sommet de l'histogramme est arrondi. Il est décrit par la formule suivante :

$$Ku = \frac{1}{N\sigma^4} \sum_{i=0}^{Ng} (i - m)^4 h(i)$$

➤ Contraste

Ce paramètre donne une indication sur la variation de niveaux de gris. Une forte valeur du contraste traduit de grandes variations locales. Il est défini par l'équation suivante :

$$Cont = \frac{1}{N} \sum_{i=0}^{Ng} i^2 h(i)$$

➤ Entropie

Elle représente une mesure du désordre ou de la complexité de la texture. Sa valeur est faible lorsque les valeurs de l'image sont très inégales. Elle est donnée par :

$$Ent = -\frac{1}{N} \sum_{i=0}^{Ng} h(i) \log(h(i))$$

➤ Energie

Elle donne une mesure de l'uniformité de l'histogramme. Elle est faible lorsque les valeurs de l'image ont le même ordre de grandeur. Elle est décrite par :

$$Eng = \frac{1}{N} \sum_{i=0}^{Ng} h^2(i)$$

C.2. Attributs de texture de la matrice de cooccurrence

Quatorze paramètres descriptifs des textures, tels qu'ils sont définis par *Harralick et al.* peuvent être extraits à partir de la matrice de cooccurrence. Nous donnons, ci-dessous, les principaux attributs les plus fréquemment utilisés en télédétection que nous avons retenus dans le cadre de notre étude.

➤ Corrélation (Cor)

Elle correspond à la quantité normalisée des valeurs qui indiquent le degré de la liaison linéaire existant entre deux variables. Autrement dit, ce paramètre quantifie la dépendance directionnelle des niveaux de gris et il atteint ses plus grandes valeurs lorsque θ est proche de l'orientation des lignes de la texture.

$$Cor = \frac{\sum_{i=0}^{Ng-1} \sum_{j=0}^{Ng-1} (i - \mu_x)(j - \mu_y) M(i, j, R)}{\sigma_x^2 \sigma_y^2}$$

Où : $\mu_x, \mu_y, \sigma_x^2, \sigma_y^2$ représentent les moyennes et les variances respectivement selon les lignes et les colonnes qui sont données par les formules suivantes :

$$\begin{aligned}
\mu_x &= \sum_{i=0}^{N_g-1} i M_x(i) & \mu_y &= \sum_{j=0}^{N_g-1} j M_y(j) \\
\sigma_x^2 &= \sum_{i=0}^{N_g-1} (i - \mu_x)^2 M_x(i) & \sigma_y^2 &= \sum_{j=0}^{N_g-1} (j - \mu_y)^2 M_y(j) \\
M_x(i) &= \sum_{j=0}^{N_g-1} M(i, j, R) & M_y(j) &= \sum_{i=0}^{N_g-1} M(i, j, R)
\end{aligned}$$

➤ **Contraste (Cont)**

Ce paramètre mesure les variations locales des niveaux de gris, c'est-à-dire il représente une mesure naturelle de la dispersion des niveaux de gris. Une petite valeur de contraste représente une texture grossière décrit donc une forte concentration des occurrences de niveaux de gris sur la diagonale principale de la matrice de cooccurrence et. Par contre une grande valeur de contraste définit une texture fine et représente des occurrences étalées autour de la diagonale principale. Dans le cas d'une image présentant une faible dynamique, les valeurs de contraste sont très faibles ce qui ne permet pas alors de discriminer des sous-structures particulières. Ce paramètre est défini par :

$$Cont = \sum_{i=0}^{N_g-1} \sum_{j=0}^{N_g-1} (i - j)^2 M(i, j, R)$$

➤ **Second Moment Angulaire (SMA)**

Appelé aussi énergie (Eng), ce paramètre permet de mesurer l'homogénéité de l'image. Lorsqu'il est élevé on retrouve souvent le même couple de pixels, donc une texture homogène. On retrouve ce cas si le niveau de gris est uniforme ou s'il y a périodicité. Lorsqu'il y a peu de zones homogènes sa valeur est faible, ce qui explique l'existence de beaucoup de transitions de niveaux de gris dans ce cas. Il est donné par l'expression suivante :

$$Eng = \sum_{i=0}^{N_g-1} \sum_{j=0}^{N_g-1} M^2(i, j, R)$$

➤ **Directivité (Dir)**

Elle représente la somme des éléments diagonaux de la matrice de cooccurrence. Sa valeur est de plus en plus importante lorsque la texture possède une orientation privilégiée dans le sens de la translation. Elle est exprimée par l'équation suivante :

$$Dir = \sum_{i=0}^{N_g-1} M(i, i, R)$$

➤ Entropie (Ent)

Elle sert à caractériser le degré de granularité de l'image, ce qui nous donne une mesure de la complexité de la texture. C'est un indicateur du désordre que peut présenter une texture. Sa valeur est faible lorsqu'on a souvent le même nombre de pixels et elle est forte si chaque couple est peu représenté. Elle est définie par la formule suivante :

$$Ent = \sum_{i=0}^{N_g-1} \sum_{j=0}^{N_g-1} M(i, j, R) \log[M(i, j, R)]$$

➤ Homogénéité locale ou Moment de différence inverse (Idm)

Cet attribut renseigne sur l'existence de plages uniformes de texture en affectant un poids de plus en plus faible au fur et à mesure qu'on s'éloigne de la diagonale principale. L'homogénéité donne donc une idée des similarités locales. Plus sa valeur est élevée, plus la texture est grossière et inversement. Elle est décrite par l'expression suivante :

$$Idm = \sum_{i=0}^{N_g-1} \sum_{j=0}^{N_g-1} \frac{1}{1 + (i - j)^2} M(i, j, R)$$

➤ Uniformité (Unif)

Elle indique le degré de répétition du même niveau de gris. Sa valeur est d'autant plus élevée qu'un même niveau de gris apparaît dans la texture.

$$Unif = \sum_{i=0}^{N_g-1} M^2(i, j, R)$$

Annexe D

Formation et classification des nuages

D.1. Définition d'un nuage

Un nuage est défini comme étant un ensemble visible de minuscules particules d'eau liquide ou de glace, ou les deux à la fois, en suspension dans l'atmosphère (Glickman 2000) qui se forment par condensation de la vapeur d'eau lorsque l'air humide se refroidit.

D.2. La formation des nuages (Cours E1)

L'air chaud contenant de la vapeur d'eau plus léger que l'air froid s'élève en altitude sous l'action de ce dernier provoquant ainsi la diminution de sa pression et son refroidissement. Ce refroidissement provoque la condensation de la vapeur d'eau et forme un nuage contenant de fines particules (gouttelettes) liquides autour de fines particules solides qui grossissent en s'agglomérant entre elles.

Le nuage semble rester en suspension dans l'air bien qu'en réalité les gouttelettes tombent à raison de quelques centimètres par seconde. Ceci s'explique par le fait que sous leur poids, ces particules ont tendance à tomber mais étant très légères en début de cycle, les frottements de l'air s'opposent à leur chute. Au fur et à mesure que les gouttelettes grossissent, et passé un certain poids elles se transforment en véritable pluie notamment dont la vitesse de chute peut centupler si les vents sont forts.

La forme et la taille d'un nuage dépendent de la force et du degré d'humidité du courant ascendant (ou courant thermique) qui donnent naissance aux nuages de "convection". Par exemple, un courant ascendant suffisamment humide qui atteint 8 km d'altitude donne naissance à un cumulus.

D.3. Classification des nuages

Les nuages se différencient entre eux principalement d'un point de vue aspect et couleur. L'aspect d'un nuage dépend essentiellement de la nature, des dimensions, du nombre et de la répartition dans l'espace des particules qui le constituent. Sa couleur dépend de l'intensité et de la

couleur de la lumière qui l'éclaire (diffusion de Mie), ainsi que des positions relatives de l'observateur et de la source de lumière par rapport au nuage.

Etant en perpétuelle évolution, les nuages peuvent se présenter, par conséquent, sous plusieurs variétés de formes. Cependant, il est possible de les regrouper en quelques familles qui présentent des similitudes et des caractéristiques communes qu'on peut observer souvent. Les nuages peuvent être classifiés selon leur genre, leur espèce ou leur altitude.

D.3.1. Les nuages selon leur genre

La classification des nuages la plus utilisée actuellement est basée sur l'existence de dix groupes principaux, appelés "genres" qui sont en exclusion mutuelle. La nomenclature approuvée par l'OMM en 1956, permet de répartir les différents types de nuages dans dix genres.




Figure D.1 : Les différents genres de nuages

D.3.2. Les nuages selon leur espèce

Afin préciser la nature des nuages, les genres ont été divisés en 14 espèces désignées par un terme latin. Ces espèces qui constituent autant de catégories distinctes, ne s'appliquent pas indifféremment à n'importe quel type de nuage; certaines sont propres aux cirrus, d'autres aux cumulus ou encore aux cumulonimbus.

D.3.3. Les nuages selon leur altitude

Le niveau dans lequel se situent la base et le sommet des nuages est très important d'un point de vue opérationnel. Trois étages constituent la partie de l'atmosphère dans laquelle se présentent habituellement les nuages : l'étage supérieur, l'étage moyen et l'étage inférieur. Les limites de ces étages sont fonction de l'altitude; le tableau ci-dessous donne ces limites pour les régions polaires, tempérées et tropicales (3' = 1m).

REGIONS			
Etages	Polaires	Tempérées	Tropicales
Supérieur	> 10000'	>16000'	> 20000'
Moyen	6500 - 13000'	6500 - 23000'	6500 - 26000'
Inférieur	< 6500'	< 6500'	< 6500'

Tableau D.1 : Les limites des différents étages sont fonction de l'altitude

Les nuages d'un certain genre se retrouvent le plus fréquemment dans les étages suivants :

- a) **Etage supérieur** : dans cet étage les nuages se forment au dessus de 8 000 mètres dans la région froide de la troposphère. Ils sont composés de cristaux de glace car, à cette altitude, l'eau gèle quasiment toujours. Il contient les cirrus (Ci), les cirrocumulus (Cc) et les cirrostratus (Cs).
- b) **Etage moyen** : les nuages de cet étage, appelés aussi nuages intermédiaires, sont constitués de gouttelettes d'eau et se développent entre 3 000 et 6 000 mètres et sont classés en utilisant le préfixe alto-(altocumulus (Ac), altostratus (As)).
- c) **Etage inférieur** : Les nuages de l'étage inférieur, de basses altitudes, également formés par des gouttelettes d'eau, se situent à une altitude généralement inférieure à 1,5 km. Lorsque ces derniers rencontrent la terre, on les appelle brouillard. Ce groupe comprend trois formes principales : les strato-cumulus, les stratus et les nimbo-stratus.

C'est cette distribution qui a donné leur surnom aux familles de nuages : nuages bas, nuages moyens et nuages élevés.

Trois exceptions peuvent avoir lieu :

- Le nimbostratus (Ns) est presque invariablement observé au-delà de 2000 m d'altitude (6500'), dans l'étage moyen, mais il déborde généralement dans les deux autres étages lorsqu'il déverse ses précipitations.
- Les cumulus (Cu) et cumulonimbus (Cb) ont habituellement leurs bases dans l'étage inférieur, mais sous l'effet d'une forte activité convective ils peuvent présenter une telle extension verticale que leurs sommets atteignent souvent l'étage supérieur.

Le tableau D.4 synthétise la hauteur, l'épaisseur, l'aspect et les hydrométéores constitutifs de chaque nuage en fonction de l'étage où il se trouve.

D.4. Les précipitations (Cours E1)

En météorologie, le terme précipitation représente toutes les eaux météoriques qui tombent sur la surface de la terre causées par un changement de température ou de pression. Soumises à des processus de condensation et d'agrégation à l'intérieur des nuages, elles deviennent trop lourdes pour demeurer en suspension dans l'atmosphère. Elles peuvent se présenter sous forme liquide telle que la bruine et la pluie ou sous forme solide comme la neige et la grêle. Leur formation dépend de la stabilité ou de l'instabilité de l'atmosphère.

Il existe différents types de précipitations qui peuvent être classées essentiellement en deux familles : les précipitations convectives et les précipitations stratiformes.

Les précipitations convectives sont associées à des nuages de types "cumulus" ou "cumulonimbus" qui ne durent pas longtemps. Elles sont de forte intensité, peuvent être accompagnées d'orage ou de grêle et couvrent des petites zones. Il s'agit des précipitations des zones de convergence ou des précipitations frontales ou de type cyclonique.

Les précipitations stratiformes sont associées à des nuages de types "stratus" ou "nimbostratus" et qui durent longtemps. Elles sont de faible intensité et couvrent une grande étendue et se produisent dans les zones de basse pression et les creux. Elles peuvent être des précipitations côtières ou des précipitations orographiques.

	Genre	Base hauteur (km)	Epaisseur (km)	Aspect	Hydrométéores constitutifs
NUAGES HAUTS	<i>Cirrus</i> (Ci)	7-12	0,2-1,8	Blancs ; fibreux en forme de virgule	Cristaux de glace
	<i>Cirrocumulus</i> (Cc)	6-11	0,2-1	Blancs ; nappe d'éléments de largeur apparente inférieure à 1°, aspect moutonneux ondulé	Cristaux de glace, eau surfondue parfois
	<i>Cirrostratus</i> (Cs)	6-11	0,2-1	Voile blanchâtre ou bleuté uniforme, couvrant partiellement ou totalement le ciel	Cristaux de glace ⇒ halos lumineux
NUAGES MOYENS	<i>Alto cumulus</i> (Ac)	3-5	1,5	Blanchâtre ou grisâtre ; floconneux, ondulé avec des éléments de largeur apparente entre 1° et 5°	Gouttelettes d'eau, cristaux de glace parfois
	<i>Altostratus</i> (As)	2-5	2	Voile uniforme grisâtre couvrant totalement le ciel. Le soleil y est vu comme à travers un verre dépoli	Cristaux de glace, gouttelettes d'eau ⇒ pluie, neige
	<i>Stratocumulus</i> (Sc)	0,6-2	0,6	Proche de (Ac) mais éléments plus gros	Gouttelettes d'eau ⇒ pluie fine et rare
NUAGES BAS	<i>Stratus</i> (St)	0-0,5	0,3	Couche compacte grise diffuse, aspect brumeux ⇒ brouillard quand contact avec le sol	Gouttelettes d'eau, rare cristaux de glace ⇒ pluie et neige fines
	<i>Nimbostratus</i> (Ns)	0,4-2	3	Couche grise et sombre étendue masquant complètement le soleil, aspect flou	Cristaux de glace, gouttelettes d'eau, glace ⇒ pluie, neige
NUAGES ÉTENDUS VERTICALEMENT	<i>Cumulus</i> (Cu)	0,5-2	1	Blancs, denses, bien délimités, aspect bouillonnant	Gouttelettes d'eau
	<i>Cumulonimbus</i> (Cb)	0,4-3	9	Dense et puissant, partie supérieure lisse et fibreuse caractérisée par une forme d'enclume	Gouttelettes d'eau, cristaux de glace ⇒ fortes pluies, neige, grêle

Tableau D.2 : Caractéristiques des différents genres de nuages de chaque étage.

BIBLIOGRAPHIE

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

Ahmed M.N, S.M. Yamany, N.A. Mohamed, and A. Farag, Sept. 19-22, 1999: A modified fuzzy c-means algorithm for MRI bias estimation and adaptive segmentation, *in Proc. Second International Conference on Medical Image Computing and Computer- Assisted Intervention, MICCAI'99*, Cambridge (England), p. 72-81.

Ameur, S.;2000: “Analyse de la couverture nuageuse par traitement par traitement d'image satellitaires”, *thèse de doctorat en Electronique*, Université Mouloud MAMMERI de Tizi Ouzou.

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.

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

Arthur, D. et 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.

Ashton.E.A et Parker .K.J, 1995: “A Multiple resolution Bayesian segmentation of ultrasound images”, *Ultrasonic Imaging*, Vol.17, p.291-304.

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

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.

Bankert, R. L., et Aha, D.W.,1996: “Improvement to neural network cloud classifier”, *J. Appl. Meteorol.*, 35, 2036-2039.

Bankert, R. L.,1994: "Cloud classification of AVHRR imagery in maritime regions using a probabilistic neural network", *J. Appl. Meteorol.*, 33, 909-918.

Battan, L. J.,1959: Radar meteorology. *University of Chicago Press*, 161 pp.

Beil, F.M.,1999 : "Approche structurelle 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.

Berges, J. C., et Chopin, F.;2004: "Satellite rainfall estimation using a feed forward neural network: Improvements and limitations", *Proceedings of the 14th International Conference on Clouds and Precipitation (ICCP)*, Bologna, Italy, 273-276.

Bertolino,P and Montanvert,A; 1996: "Multiresolution segmentation using the irregular pyramid". In *IEEE International Conference on Image Processing*, pages 257–260, Lausanne, Switzerland, September 16-19.

Besag,J.E, 1974 : *Spatial interaction and the statistical analysis of lattice systems with discussion*. J.Royal Statist. Soc., Sene B, vol. 26, n° 2, p. 192-236.

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.

Bonn, F., and Rochon, G. ;1992: "Précis de télédétection" - Volume 1 - Principes et Méthodes. Universités Francophones, Presses de l'Université du Québec/AUPELF. pp. 485.

Bouman. C A and M. Shapiro,1994: "A multiscale random field model for bayesian image segmentation," *IEEE Trans. on Image Processing*, 1994, vol. 3, n° 2, p. 162-177.

Bouman. C and B. Liu,1991: Multiple resolution segmentation of textured images, *IEEE Trans. on Pattern Anal. Machine Intell.*, 1991, vol. 13, n° 2, p. 99-113.

Buf, J.M.H.; 1989 : "Towards unsupervised texture segmentation using Gabor spectral decomposition", *5th Int. Conf. on Image Analysis and Processing* ; Positano (Italy) ; 65-72 pp.

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., et 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., and Calpe-Maravilla, J.;2006b: "Composite kernels for hyperspectral image classification". *Geoscience and Remote Sensing Letters*, 3(1) :93–97.

Chou.P. B and Brown, .C. M, 1990: The theory and pratice of bayesian image labeling, *Int. Journal of Computer Vision*, vol.4, p.185-210.

Chuang, K., Tzeng, H., Chen, S., Wu, J., and Chen, T. "Fuzzy c-means clustering with spatial information for image segmentation".;2006: *Computerized Medical Imaging and Graphics*, 30(1) :9–15.

Collet.C, P. Thourel, P. Bouthemy, and P. Pérez, 1995 : Détection d'ombres sur images sonar par une analyse multirésolution et une modélisation markovienne," in *Proc. Actes 14ème colloque GRETSI*, Juan les Pins, p. 569-572.

Collet.C, P. Thourel, P. Pérez, and P. Bouthemy,1996: "Hierarchical MRF modeling forsonar picture segmentation," in *Proc. IEEE International Conference on Image Processing*, Lausanne (Switzerland), p. 979-982.

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.

Cocquerez.JP, S.Philipp,1995 : Analyse d'image: filtrage et segmentation, *ed. Masson*, Paris.

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.

Del Frate, F., Ortenzi, A., Casadio, S., et 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., H. Andrieu, et J. D. Creutin.;2000: "Quantification of Path-Integrated Attenuation for X- and C-BandWeather Radar Systems Operating in Mediterranean Heavy Rainfall". *J. Appl. Meteorol.*, 39, 840–850.

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

Derin and Elliott, 1987: Modeling and Segmentation of Noisy and Textured Images Using Gibbs Random Fields. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, vol. PAMI-9, no. 1, pp. 39-55.

D'hondt, O. ;2006 : "Analyse spatiale de texture non stationnaire dans les images SAR",*Thèse de l'Université de Rennes 1*.

Diop, O.,2007 : " Détection de nuages de poussière dans les images Météosat à l'aide des attributs de textures et de la fusion de segmentations : application à la zone sahélienne du continent africain" ; *Thèse de doctorat, Université de Rennes*.

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

E-cours1: "Les précipitations", site internet : georepere.e-monsite.com/medias/files/chap-13-precipitations.pdf

E-cours2: www.prevision-meteo.ch/comprendre/classification-des-nuages-selon-omm

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., et 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. et 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, 2012.

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*, 19-21.

Früh, B., Bendix, J.,Nauss, T., Paulat, M., Pfeiffer, A. et 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.

Gath.I and Geva. A.B, 1989: "Unsupervised optimal fuzzy clustering", *IEEE Trans. on Pattern Anal. Machine Intell.*, Vol. 11, N°4, p. 773-781.

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., et 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. et 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. et Mugglestone, M.A.;1991: "Textural and spectral features as an aid to cloud classification", *International Journal of Remote Sensing* , vol. 12, n° 5 ; 953-968 pp.

Gualtieri, J. et 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.

Hammouda, A.,1995 : "connaissance et modélisation des précipitations pour l'hydrologie urbaine a travers l'exemple de l'agglomération nancéienne" ; *Thèse de doctorat, Université de Nancy*.

Haralick R.M., Shanmugam K. and Dinstein I.,1973:"Textural features for image classification" ; *IEEE Transactions on Systems, Man and Cybernetics* ; vol. 3 ; n° 6 ;610-621 pp.

Haralick, R.M.;1979: "Statistical and structural approaches to texture", *Proceedings IEEE* , vol. 67 ; N° 5 ; 786-803 pp.

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.

Hillion et al, 1989 : *Le traitement des images de télédétection: aperçus et perspectives Télédétection en francophonie*, AUPELF- UREF, John Libbey Eurotext, Paris, pp. 97-110.

Hornik, K., Stinchcombe, M. B., et White, H.;1989: "Multilayer feedforward networks are universal approximators". *Neural Networks*, 2(5):359–366.

Houze, R. ;1993: "Cloud dynamics". *International Geophysics Series*, 53, Academic Press, 573 pp.

Huang, C., Davis, L., et 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., et 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).

Inoue, T.;1987: “An instantaneous delineation of convective rainfall areas using split window data of NOAA-7 AVHRR”. *J. Meteorol. Soc. Japan*. Vol. 65, pp. 469–481, 1987.

Isabelle, C : Cours “Analyses de textures en traitement d’images”.

Jain, S et 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, August.

Jones, D. ;1956: “Rainfall drop-size distribution and radar reflectivity”. *Illinois State Water Survey*.

Karimi, Y., Prasher, S. O., Patel, R. M., et 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.

Kato,Z, M. Berthod, and J. Zerubia,1993: Parallel Image Classification using Multiscale Markov Random Fields. In Proc. ICASSP, Minneapolis.

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.

Kervrann.C and F. Heitz,1993: A Markov random field model-based approach to unsupervised texture segmentation using local and global spatial statistics, Rennes (France) : *IRISA*, 30 p., *Internal Report* 752.

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*.

Kühnlein, M., Thies, B., Nauss, T. et 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>.

Kunt.M and all, 1993 : “Traitement numérique des images “. *Presses Polytechniques et Universitaires Romandes et CENT-ENST*, Lausanne.

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

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

- Lazri, M., Ameur, Z., Ameur, 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., et Ackerman, S.;2004: "Classification of Satellite Radiance Data by Multicategory Support Vector Machines," *Journal of Atmospheric and Oceanic Technology*, 21, 159–169.
- Levizzani, V et 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. et 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. et Xiao, X.; 2007: "Multispectral image segmentation by a multichannel watershed-bases approach". *International Journal of Remote Sensing*, 28(19-20) :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.
- Maître H.,2003 : "Le traitement des images" ; Hermès ; Paris ; Collection IC2.
- 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.
- Marshall, J. S., W. Hitschfeld, et K. L. S., Gunn.;1955: "Advances in Radar Weather". *Adv. Geophys.*, 2, 1–56.
- Matsoukas, C., S. Islam, R. Kothari.;1999: "Fusion of radar and rain gage measurements for an accurate estimation of rainfall", *J. Geophys. Res.*, 104, 31437-31450.
- Matsuyama, T., Miura, S et Nagao, M. ;1983 : "Structural analysis of natural textures by Fourier transformation" ; *Compt. Vis. Graph. Image Processing* ; Vol. 25 ; 347-362 pp.

McDonald, S., Niemann, K., Goodenough, D., Dyk, A., West, C., et 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, pages 552–554.

Melgani, F. et 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., et 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.

Metropolis.N, A. W. Rosenbluth, M. W. Rosenbluth, and A. H. Teller,1953: *Equation of state calculation by fast computing machines*, The Journal of Chimical Physics, 953, vol. 21, n° 6, p. 1087-1092.

Mignotte.M,1998 :Segmentation d'images sonar par approche markovienne hiérarchique non supervisée et classification d'ombres portées par modèles statistiques, *Thèse de Doctorat*, Université de Bretagne Occidentale, 1998, 226 p.

Minsky, Marvin et Seymour, A.;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", Papert, Perceptrons, MIT Press.

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

Mohia, M., Ameer, S., LAZRI, M., Brucker, J.M.; 2014: "Rainfall intensity classification method based on textural and spectral parameters from MSG-SEVIRI". *International Review on Computers and Software (IRECOS)*, volume 9, Number 7, p.1302– 1313.

Mohia, M., Ameer, S., LAZRI, M., Brucker, J.M.; 2016: "Combination of Spectral and Textural Features in the MSG Satellite Remote Sensing Images for Classifying Rainy Area into Different Classes". *Journal of Indian Society of Remote Sensing (ISRS)*, volume 45, Issue 5, p.759– 771.

Müller, M. D., Kaifel, A. K., Weber, M., Tellmann, S., Burrows, J. P., et 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.

Muzzolini .R et al, 1993: "Multiresolution texture segmentation with application to diagnostic ultrasound images", *IEEE Trans.on Medical Imaging*, vol.12, N°1, p. 108-123.

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., et 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.

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

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

Pappas.T.N, 1992 : "An adaptive clustering algorithm for image segmentation", *IEEE Trans.on Signal Processing*, Vol.40, N°4, p.901-914.

Pichler.O, A. Teuner, and B. Hosticka,1998: "An unsupervised texture segmentation algorithm with feature space reduction and knowledge feedback," *IEEE Trans. Image Processing*, vol. 7, n° 1, p. 53-61.

Probert-Jones, J. R. "The radar equation in meteorology. *Q. J. R". Meteorol. Soc.*, **88**, 485–495, 1962.

Prony, O., Descombes, X., et Zerubia, J. ;2000 : "Classification des images satellitaires hyperspectrales en zone rurale et périurbaine". *Rapport de recherche 4008*, INRIA.

Pruppacher, H. Klett,J.D.;1997: "Microphysics of clouds and precipitation". *Kluwer Academic Publishers*, 2nd Ed., 943 pp.

Rellier, G. ;2002 : "Analyse de texture dans l'espace hyperspectral par des méthodes probabilistes". *PhD thesis*, Nice Sophia-Antipolis, France.

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. et Holleman, I.;2009: "SEVIRI rainfall retrieval and validation using weather radar observations". *Journal of Geophysical Research*, 114(D21), 1–13.

Roli, F. et 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.

Rosenberger C. ;1999 : "Mise en oeuvre d'un système adaptatif de segmentation d'images", Thèse de l'université de Rennes.

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

Rosenfeld A. et Troy E.,1970: "Visual texture analysis" ; *Conference record for symposium on feature extraction and selection in pattern recognition IEEE* ; publication 70 ; 115-124 pp.

Rosenfeld, D. et 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>.

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

Rouquet.C and Bonton.P, 1997: "Segmentation en régions non supervisée par relaxation markovienne, une étude comparative", in *Proc. Actes 16^{ème} colloque GRETSI*, Grenoble, Sept. 15-19, p.31-34.

Sali E. and Wolfson H. ,1992: "Texture classification in aerial photographs and satellite data" ; *International Journal of Remote Sensing* ; vol. 13 ; n° 18 ; 3395-3408 pp.

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. et Despaux, 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. p. 51-55.

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

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

Sigelle, M. et Tupin, F. ;1999 : "Champs de markov en traitement d'images".

Smartt, H. et Tyo, J.;2006: "Classification of hyperspectral spatial/ spectral patterns using gauss-markov random fields". In *Proceedings of SPIE - The International Society for Optical Engineering*, volume 6233 I.

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

Thies, B., Nauss, T. et Bendix, J.;2008c: "Precipitation process and rainfall intensity differentiation using Meteosat Second Generation SEVIRI data". *Journal of Geophysical Research*, 113, 19. <http://dx.doi.org/10.1029/2008JD010464>.

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.

Tsintikidis, D., Haferman, J. L., Anagnostou, E. N., Krajewski, W. F., Smith, T. F.;1997: "A neural network approach to estimating rainfall from spaceborne microwave data". *IEEE Transactions on Geoscience and Remote Sensing*, 35, 1079-1092.

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.

Vemuri.B.C, S. Rahman, and J. Li,1995: "Multiresolution adaptive k-means algorithm for Segmentation of brain MRI," in *Proc. Intl. Comp. Sci. Conf. on Image Analysis and Computer Graphics*, Hong Kong, p. 347-354.

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.

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

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

Welch, R. M., Sengupta, S. K., Goroch, A. K., Rabindra, P., Rangaraj, N., Navar, M. S.;1992: "Polar cloud and surface classification using AVHRR imagery: An intercomparaison of methods". *Journal of Applied Meteorology*, 31, 405-420.

Wexler, R. et Atlas, D.,1963: "Radar Reflectivity and Attenuation of Rain". *J. Appl. Meteorol.*, 2, 276–280.

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*.

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.