



République Algérienne Démocratique et Populaire  
Ministère de l'Enseignement Supérieur et de la Recherche Scientifique



## **Université Amar Thelidji- Laghouat**

**FACULTE : Technologie**

**DEPARTEMENT : Electronique**

### **MEMOIRE DE MASTER**

Présenté par :

**Gahgouhi Aicha**

et

**Cherifi Fatima**

**DOMAINE : SCIENCE ET TECHNIQUE**

**FILIERE : AUTOMATIQUE**

**OPTION : AUTOMATIQUE ET INFORMATIQUE INDUSTRIEL**

### **Thème**

**Utilisation des champs de Markov pour régulariser  
la classification des images: cas des images  
satellitaires**

#### **Jury de soutenance :**

<b>Nom et Prénom</b>	<b>Grade</b>	<b>qualité</b>
Mr Belkheiri Mohamed	Professeur	Président
Mr Reggab Mourad	MCB	Examineur
Mme Benkouider Fatiha	MCB	Rapporteur

Promotion: Septembre- 2020

## ملخص

الهدف من هذه المذكرة هو الجمع بين استخدام الخوارزمية التصنيفية و حقول ماركوف لتقسيم صورة القمر الصناعي من نوع سبوت الى مناطق مختلفة ، يسمح لنا تصنيف الخوارزمية التصنيفية بالحصول على مناطق مدمجة في الفضاء اللوني ولكن المناطق التي تم الحصول عليها مجزأة على مستوى الصورة. هذا يرجع إلى حقيقة أنه لم يتم أخذ أي اعتبار للمعلومات الفضائية أثناء التصنيف بواسطة الخوارزمية التصنيفية. من اجل حل هذه المشكلة ،نستخدم نموذج حقول ماركوف التي تسمح بالحصول على تصنيفات أكثر انتظامًا من خلال تفضيل الانتظام بين وحدات البكسل المجاورة . ومع ذلك ، فإن استخدام هذا النموذج يفرض عددًا معينًا من الخيارات : اختيار نظام الجوار للمجموعات ، واختيار الإمكانات المرتبطة بالزمر، واختيار المقدر وطريقة التحسين .

**الكلمات المفتاحية :** الصورة القمرية سبوت ، التجزئة ، حقول ماركوف ، خوارزمية الأوضاع الشرطية المتكررة

## Résumé

Le but de ce mémoire est de combiner l'utilisation des K-means et des champs de Markov pour segmenter en régions distinctes une image satellitaire SPOT. La classification par K-means nous permet d'obtenir des régions compactes dans l'espace RGB des couleurs, cependant les zones obtenues sont fragmentées au niveau de l'image. Cela est dû au fait qu'aucune information spatiale n'a été prise en compte lors de la classification par K-means. A fin de résoudre ce problème nous utilisons le formalisme des champs de Markov qui permet d'obtenir des classifications plus régulières en favorisant une régularité entre les pixels voisins. Cependant l'utilisation de ce modèle impose un certain nombre de choix : choix du système de voisinage pour les cliques, choix des potentiels associés aux cliques, choix de l'estimateur et de la méthode d'optimisation.

**Mots clefs:** Image SPOT, segmentation, champ de Markov, ICM

## **Abstract**

The goal of this thesis is to combine the use of k-means and Markov fields to segment a SPOT satellite image into distinct regions. The classification by k-means allows us to obtain compact regions in the RGB color space; however the zones obtained are fragmented at the image level. This is due to the fact that no spatial information was taken into account during the classification by k-means. In order to solve this problem we use the formalism of Markov fields which allows obtaining more regular classifications by favoring regularity between the neighboring pixels. However, the use of this model imposes a certain number of choices: choice of the neighborhood system for the cliques, choice of the potentials associated with the cliques, choice of the estimator and the optimization method.

**Key words:** SPOT Image, Segmentation, Markov field, ICM

# *Dédicaces*



Je dédie ce travail :

## **À ma chère mère**

Pour son grand amour, ses sacrifices et toute l'affection qu'elle m'a toujours offerte.

## **À mon cher père**

Pour sa patience et ses considérables sacrifices pour me parvenir à ce niveau

À mes chers frères *Azzedine, Zakaria* et *Mahdi*

À mes grands-parents, mes oncles, mes tantes, mes cousins, cousines et toute ma grande famille

À ma chère *Mme Fatiha Benkouider.*

Pour tous mes ami(e)s

Et toute personne qui a participé de près ou de loin à mettre en œuvre

Ce modeste travail

...Merci.

**AICHA**

# Dédicaces



Je dédie ce modeste travail à celle qui m'a donnée la vie, le symbole de tendresse, qui s'est sacrifiée pour mon bonheur et ma réussite,

**A ma mère**

A mon père école de mon enfance, qui m'a toujours poussé et motivé dans mes études. Sans lui, je n'aurais certainement pas fait d'études supérieures

Que dieu les garde et les protège

A mes adorables sœurs : ***Imane , kholoud , mariya***

A mon chère frère ***Mohamed Taher***

A mes amis en particulier, ***Wassila Benchikh Ikram Soufari et Ahmed Benammar***

A mon petit bébé ***Yahia***

A mon encadreur ***Mme Benkouider Fatiha.***

A toute la promotion 2019-2020.

A tous ceux qui me sont chers.

A tous ceux qui m'aiment.

A tous ceux que j'aime

Je dédie ce travail

***Fatima***

# Remerciements

*Tout d'abord, Louange à notre Seigneur "ALLAH" qui nous a doté de la force, de la santé, de la volonté, du courage et patience qui nous ont été utiles tout le long de notre parcours. Louange à notre créateur qui nous a incité à acquérir le savoir.*

*Nous adressons nos sincères remerciements à notre encadreur **Mme Fatiha Benkouider**. Qu'elle trouve ici l'expression de notre plus profonde reconnaissance et gratitude pour son aide qu'elle ne nous a jamais refusée malgré ses responsabilités nombreuses. Nous la remercions pour tout le temps qu'elle nous a consacré, ses encouragements et ses conseils constructifs. Elle a contribué à ce travail de recherche de façon incommensurable. Sa rigueur intellectuelle a permis au projet de suivre son chemin. Nous la remercions également pour la confiance qu'elle a su nous accorder jusqu'à la dernière minute.*

*Nous adressons aussi nos vifs remerciements aux membres des jurys pour avoir bien voulu examiner et juger ce travail.*

*Nous souhaitons exprimer nos vifs remerciements à tous les enseignants du département d'électronique qui nous ont permis d'acquérir des connaissances.*

*Par la même occasion, nous tenons à remercier vivement nos deux chères familles pour leurs encouragements et tous ceux qui nous aidés de près ou de loin dans tout le long de notre parcours.*

**AICHA & FATIMA**

## Liste des abréviations

<b>Pixel</b>	<b>P</b> icture <b>é</b> lément
<b>RVB</b>	<b>R</b> ouge, <b>V</b> ert, <b>B</b> leu
<b>RADAR</b>	<b>R</b> adio <b>D</b> étection <b>A</b> nd <b>R</b> anging
<b>LiDAR</b>	<b>L</b> ight <b>D</b> etection <b>A</b> nd <b>R</b> anging
<b>SPOT</b>	<b>S</b> atellites <b>P</b> our l' <b>O</b> bservation de la <b>T</b> erre
<b>HRV</b>	<b>H</b> igh <b>R</b> esolution <b>V</b> isible
<b>IKONOS</b>	dérivé du mot grec <b>eikōn</b> signifiant image
<b>HRS</b>	<b>H</b> aute <b>R</b> ésolution <b>S</b> téréoscopique
<b>HRG</b>	<b>H</b> aute <b>R</b> ésolution <b>G</b> éométrique
<b>HRVIR</b>	<b>H</b> igh <b>R</b> esolution <b>V</b> isible <b>I</b> nfrared detectors
<b>PIR</b>	<b>P</b> roche <b>I</b> nfra <b>R</b> ouge
<b>PAN</b>	<b>P</b> anchromatique
<b>LANDSAT</b>	<b>L</b> and Remote-Sensing <b>S</b> atellite
<b>ISODATA</b>	<b>I</b> terative <b>S</b> elf- <b>O</b> rganizing <b>D</b> ata <b>A</b> nalysis <b>T</b> echnics
<b>CMC</b>	<b>C</b> hamps de <b>M</b> arkov <b>C</b> achés
<b>EM</b>	<b>E</b> xpectation <b>M</b> aximisation
<b>SEM</b>	<b>S</b> tochastic <b>E</b> xpectation <b>M</b> aximisation
<b>ICE</b>	<b>I</b> térative <b>C</b> onditional <b>E</b> stimation
<b>ICM</b>	<b>I</b> terated <b>C</b> onditional <b>M</b> ode
<b>MAP</b>	<b>M</b> aximum <b>A</b> <b>P</b> osteriori
<b>MPM</b>	<b>M</b> ode à <b>P</b> osteriori des <b>M</b> arginales
<b>CNES</b>	<b>C</b> entre <b>N</b> ational d' <b>E</b> tudes <b>S</b> patiales

# Liste des figures

<b>Figure 1.1</b>	Principe de la Télédétection .....	6
<b>Figure 1.2</b>	Les étapes de télédétection.....	7
<b>Figure 1.3</b>	Satellite SPOT .....	10
<b>Figure 1.4</b>	Spectre électromagnétique de la végétation chlorophyllienne.....	12
<b>Figure 2.1</b>	Définition multispectrale d'un objet .....	15
<b>Figure 2.2</b>	Classification dirigée: sites d'entraînement (à gauche) et l'image complètement classifiée (à droite).....	18
<b>Figure 2.3</b>	Principe de fonctionnement général de k-means.....	23
<b>Figure 2.4</b>	Démonstration des quatre étapes de k-means avec (K=3).....	24
<b>Figure 3.1</b>	Cliques associées à un système de voisinage en 4-connexité et en 8-connexité.....	29
<b>Figure 3.2</b>	Evolution de la fonction d'énergie en fonction de la température .....	33
<b>Figure 4.1</b>	Extrait de l'image SPOT5 de la région de Bordj Senouci (Laghouat, Algérie).....	37
<b>Figure 4.2</b>	Résultats de la classification par la méthode de K- moyennes pour différent nombres de classes.....	38
<b>Figure 4.3</b>	Différents résultats de la classification différents nombre de classes, (a) et (c) par K moyennes, (b) et (d) par champs de Markov	39
<b>Figure 4.4</b>	Resultats de l'application R-k-Moyennes par CMC; cas de deux classes, (a) sans régularisation; (b) avec régularisation, (c) carte des classes, (d) évaluation de la température....	40
<b>Figure 4.5</b>	Resultats de l'application R-k-Moyennes par CMC: cas de quatre classes, (a) sans régularisation; (b) avec régularisation, (c) carte des classes, (d) évaluation de la température.....	41
<b>Figure 4.6</b>	Resultat pour $\beta=100$ , (a) sans régularisation, (b) avec régularisation	43

## Liste des tableaux

<b>Tableau 1.1</b>	Composition colorée en fausse couleurs	11
<b>Tableau 1.2</b>	Les bandes de l'image SPOT multispectrale	11
<b>Tableau 4.1</b>	Rôle des cliques	43
<b>Tableau 4.2</b>	Choix du coefficient de régularisation	45

# Table des matières

<b>المخلص</b> .....	<i>i</i>
<b>Dédicace</b> .....	<i>iv</i>
<b>Remerciements</b> .....	<i>vi</i>
<b>Liste des abréviations</b> .....	<i>vii</i>
<b>Liste des figures</b> .....	<i>viii</i>
<b>Liste des tableaux</b> .....	<i>ix</i>
<b>Introduction générale</b> .....	2
<b>Chapitre 1. Généralités sur la Télédétection</b> .....	4
1.1 Introduction.....	5
1.2 Principe de la Télédétection.....	5
1.2.1 Définition.....	5
1.2.2 Principe.....	5
1.2.3 Les différentes étapes de la télédétection.....	6
1.2.4 Les capteurs du satellite.....	9
1.3 Les images satellitaires SPOT.....	9
1.3.1 SPOT.....	9
1.3.2 Affichage des images.....	10
1.4 Echelles de traitement de données et choix des canaux.....	11
1.5 Conclusion.....	13
<b>Chapitre 2. Classification des images satellitaires</b> .....	14
2.1 Introduction.....	15
2.2 Définition de la classification.....	15
2.3 Principe de la classification.....	15
2.4 Eléments de la classification.....	16
2.4.1 La classe.....	16
2.4.2 La ressemblance.....	16
2.4.3 L'appartenance.....	16
2.5 Les méthodes de classification.....	17
2.5.1 Classification non supervisée.....	17

2.5.1.1 Méthodes de classification non supervisées.....	17
2.5.2 Classification supervisée.....	18
2.5.2.1 Méthodes de classification supervisées.....	19
2.6 Historique sur K-moyennes (K-means).....	22
2.6.1 Présentation de K-means.....	22
2.6.2 K-means et la segmentation d'image .....	23
2.6.3 Intérêt et limitation de la méthode K-means.....	24
2.6.4 Domaines d'applications.....	24
2.7. Conclusion.....	24
<b>Chapitre 3. Les champs de Markov.....</b>	<b>26</b>
3.1 Introduction.....	27
3.2. Historique.....	27
3.3 Champ de Markov et distribution de Gibbs.....	27
3.3.1 Système de voisinage et clique.....	28
3.3.2 Chaîne de Markov .....	29
3.3.3 Champ de Gibbs.....	30
3.4 Echantillonneur de Gibbs.....	30
3.5 Modèle markovien caché pour la segmentation d'images.....	31
3.6 Apprentissage.....	31
3.6.1 Apprentissage à données complètes.....	31
3.6.2 Apprentissage à données incomplètes.....	31
3.7 Estimation bayésienne.....	32
3.7.1 Estimateur Recuit simulé.....	32
3.7.2 Estimateur des modes conditionnels.....	33
3.7.3 Estimateur du Mode des Marginales à posteriori (MMP).....	34
3.8 Conclusion.....	35
<b>Chapitre 4. Résultats et interprétations.....</b>	<b>36</b>
4.1 Introduction.....	37
4.2 Outils et méthodes.....	37
4.3 Application de la méthode des K-moyennes à la segmentation .....	37
4.4 Résultat de la régularisation des K-moyennes par champs de Markov (R-k-Moyennes par CMC).....	39
4.5 Rôle du choix des cliques dans la régularisation.....	42

4.6 Rôle du coefficient de régularisation.....	43
4.7 Conclusion.....	44
<b>Conclusion générale</b> .....	45
<b>Référence</b> .....	48

# *Introduction générale*

## **Introduction générale**

De tout temps l'homme a cherché à se situer dans l'espace, à connaître et à comprendre l'univers qui l'entoure, à explorer le territoire qui s'offre à lui. Il a cartographié toute la surface du globe mais cela ne lui a pas suffi. Les dernières avancées technologiques lui ont permis d'envoyer des outils dans l'espace et ainsi d'obtenir des images satellites de la Terre et de l'univers [1].

L'image satellite est traitée dans le but d'en extraire le maximum d'information qui intéresse le futur utilisateur de l'image, et d'évacuer tout ce qui est superflu. Un but réaliste est la classification thématique de ces images [2]. A chaque point de l'image, on souhaite pouvoir attribuer une étiquette parmi une collection définie auparavant. Cette collection d'étiquettes est ce que l'on appelle l'ensemble des classes. Un ensemble de classes pourrait être : ville, campagne, forêt, route [3]. Ce traitement a pour but de reconnaître les différentes classes constituantes de l'image. Plusieurs techniques de l'intelligence artificielle ont été appliquées pour résoudre un tel problème par exemple : K-means Mais ces techniques n'arrivent pas à donner de bons résultats [4].

Le but de ce travail est de combiner l'utilisation des K-means et des champs de Markov pour segmenter en régions distinctes une image. La classification par K-means nous permet d'obtenir des régions compactes dans l'espace RGB des couleurs, cependant les zones obtenues sont fragmentées au niveau de l'image. Cela est dû au fait qu'aucune information spatiale n'a été prise en compte lors de la classification par K-means, ce problème est l'un des plus importants dans le cas des images satellitaires. Le formalisme des champs de Markov nous permet d'obtenir des classifications plus régulières en favorisant une régularité entre les pixels voisins. Cependant l'utilisation de ce modèle impose un certain nombre de choix : choix du système de voisinage pour les cliques, choix du potentiel associé aux cliques, choix de l'estimateur et de la méthode d'optimisation.

Cette méthode a été appliquée à une zone urbaine de Laghouat (Bordj Senouci, Laghouat) afin de discriminer l'espace urbain à partir d'une image multispectrale de SPOT2007. Les résultats obtenus sont discutés en fonction des différents choix possibles du coefficient de la distance de régularisation et en fonction des cliques.

La régularisation insistera sur la cohérence entre la classe d'un pixel et celle de ces voisins. Les champs de Markov consistent à tenir compte de l'influence du voisinage d'un point sur ce dernier. C'est donc tout naturellement cet outil mathématique que nous utiliserons pour régulariser la classification d'image [3].

Ce mémoire s'articule sur quatre chapitres outre l'introduction et la conclusion.

- Le premier chapitre est consacré à des généralités sur la télédétection, nous commençons par définir le principe de la télédétection et l'image satellitaire SPOT ainsi que les échelles de traitements et le choix des canaux.
- Le deuxième chapitre est consacré aux méthodes de classification contextuelle
- Le troisième chapitre est consacré au formalisme des champs de Markov cachés
- Le quatrième chapitre, les résultats de l'application de la méthode K-means et celle des champs de Markov régularisé sur l'image SPOT en vue d'une classification seront présenté.
- Enfin, notre travail s'achève par une conclusion générale et quelques perspectives pour les travaux à venir.

***Généralités sur la  
Téledétection***

## 1.1 Introduction

L'observation de la terre par un satellite permet d'accéder à plusieurs paramètres de surface qui sont utilisés dans différents modèles. Suivant le type de satellites utilisés, les paramètres accessibles varient. En effet, les satellites émettent un signal dans une certaine longueur d'onde puis reçoivent la réponse de la terre à ce signal. Le traitement du signal réfléchi permet alors d'obtenir les paramètres mentionnés. Suivant la longueur d'onde utilisée par le satellite et le couvert nuageux au moment de l'observation, les images obtenues sont plus ou moins nettes et le traitement des images est alors incertain. Le présent chapitre dévoile une vue générale sur les images satellitaires [2].

## 1.2 Principe de la Télédétection

### 1.2.1 Définition

La télédétection se définit comme « l'ensemble des connaissances et techniques utilisées Pour déterminer des caractéristiques physiques et biologiques d'objets par des mesures effectuées à distance, sans contacts matériels avec ceux-ci »<sup>1</sup>.

La télédétection est la discipline scientifique qui regroupe l'ensemble des connaissances et des techniques utilisées pour l'observation, l'analyse, l'interprétation et la gestion de l'environnement à partir de mesures et d'images obtenues à l'aide de plates-formes aéroportées, spatiales, terrestres ou maritimes. Elle suppose l'acquisition d'informations (caractéristiques physiques et biologiques) à distance, sans contact direct avec l'objet étudié [5].

### 1.2.2 Principe

L'image satellitaire est une image numérique, c'est-à-dire un assemblage de pixels, ou surfaces élémentaires, référencés en ligne et colonnes formant un maillage régulier de la surface totale balayée par le capteur. Chaque pixel contient une somme d'informations codées par les valeurs des comptes radiométriques et les coordonnées en pixels (figure 1.1).

A chaque surface élémentaire de l'image correspond autant de mesures numérisées qu'il existe de canaux. Il existe 256 (0 à 255) valeurs radiométriques possibles définissant une mesure de l'intensité de la lumière solaire réfléchie par la surface terrestre ayant atteint le capteur en orbite. Cette intensité, appelée luminance, est donnée dans chaque canal. De même il existe 256 niveaux de gris différents dans la table de codage associée à l'image : chaque valeur radiométrique est représentée par un niveau de gris [6].

---

<sup>1</sup> Commission interministérielle de terminologie de la télédétection aérospatiale, France, 1988).




Figure 1.1 Principe de la Télédétection (source Tanré et all, 1986)

### 1.2.3 Les différentes étapes de la télédétection

Le processus de la télédétection se résume dans les étapes suivantes (figure 1.2):

**a. Source d'énergie ou d'illumination (A)**

A l'origine de tout processus de télédétection se trouve nécessairement une source d'énergie pour illuminer la cible.

**b. Rayonnement et atmosphère(B)**

Durant son parcours entre la source d'énergie et la cible, le rayonnement interagit avec l'atmosphère. Une seconde interaction se fait dans le trajet entre la cible et le capteur.

**c. Interaction avec la cible(C)**

Une fois parvenue à la cible, l'énergie interagit avec la surface de celle-ci. La nature de cette interaction dépend des caractéristiques du rayonnement et des propriétés de la surface.

**d. Enregistrement de l'énergie par le capteur (D)**

Une fois l'énergie diffusée ou émise par la cible, elle doit être captée à distance par un capteur pour être enfin enregistrée.

**e. Transmission, réception et traitement (E)**

L'énergie enregistrée par le capteur est transmise souvent par des moyens électroniques à une station de réception ou l'information est transformée en images (numériques ou photographiques).

### f. Interprétation et analyse (F)

Une interprétation visuelle et/ou numérique de l'image traitée est ensuite nécessaire pour extraire l'information que l'on désire obtenir sur la cible.

### g. Application(G)

Lorsque l'on exploite l'imagerie satellitaire pour observer certaines caractéristiques ou certains événements particuliers, on peut parler d'applications du satellite.




Figure 1.2 Les étapes de télédétection

Il est nécessaire de mentionner que les informations contenues dans une image satellitaire brute ne peuvent pas être exploitées directement afin de pouvoir analyser les valeurs de réflectance (ou de luminance) du terre pour en étudier son évolution.

L'interprétation d'images requiert un certain nombre de prétraitements :

- l'étalonnage absolu, qui passe par la connaissance des coefficients de calibration permettant de relier la valeur numérique à la réflectance correspondante ;
- les corrections géométriques, qui sont liées à l'attitude du vecteur. Il s'agit de corriger les effets des différents mouvements secondaires du satellite (lacet, roulis, tangage) enregistrés à bord, qui déforment la géométrie de l'image ;
- la transformation de l'image satellitaire dans un système de projection cartographique traditionnel ;
- le renforcement des contrastes de l'image pour l'optimisation de l'exploitation future des données

En télédétection spatiale, deux grandes familles de capteurs existent :

1. **les capteurs actifs:** Ils produisent leur propre source d'énergie pour illuminer la cible. Autrement dit, ils dégagent un rayonnement électromagnétique dirigé vers la cible, puis ils mesurent la réponse de la cible. Ils sont basés par exemple sur la technique du Radio Détection And Ranging (RADAR) ou encore du Light Detection And Ranging (LiDAR).
2. **les capteurs passifs:** Au contraire, les capteurs passifs utilisent les rayonnements naturels du Soleil comme source d'énergie. Une fois l'énergie diffusée par la cible, les capteurs passifs mesurent la radiation transmise. Dans ces travaux de thèse, seules les images issues de capteurs passifs sont étudiées. Les images optiques sont composées de pixels dont les valeurs représentent la réflectance mesurée par le capteur du satellite. Cette dernière représente la quantité de lumière réfléchiée par la surface observée.

De manière générale, chaque image est caractérisée par [7]:

- la taille. Elle dépend de l'orbite et de l'ouverture angulaire de l'instrument, c.à.d. la fauchée représentant la surface imagée en une seule acquisition par le satellite. La taille du pixel appelée par abus de langage **résolution spatiale**. La résolution spatiale est en réalité définie par la distance minimale entre deux objets adjacents pouvant être distingués. Elle dépend des caractéristiques des détecteurs et de la lentille du capteur optique. Bien que pour une majorité des satellites la résolution spatiale peut être confondue avec la taille des pixels, ce n'est pas le cas pour certains satellites.
- son nombre de bandes spectrales appelé par abus de langage **résolution spectrale**. Plus précisément, la résolution spectrale est la capacité du capteur à discriminer les signaux de différentes longueurs d'ondes. Elle dépend donc du nombre de bandes, mais aussi de la largeur de ces bandes.
- le temps de revisite du satellite est aussi une caractéristique importante. Il représente la durée nécessaire au satellite pour imager à nouveau la même scène. Le temps de revisite dépend principalement de l'orbite et de la fauchée du satellite. D'un côté, les satellites avec une orbite géostationnaire n'observent qu'une seule région. Les principaux satellites avec une telle orbite sont ceux de télécommunications, et aussi quelques satellites météorologiques. D'un autre côté, les satellites avec une orbite basse, et souvent héliosynchrone, peuvent cartographier l'ensemble des surfaces émergées en observant chaque région toujours à la même heure.

### 1.2.4 Capteurs du satellite

Un capteur comporte trois éléments constitutifs : un système optique, un filtre spectral et un détecteur. Le système optique fixe l'angle instantané de prise de vue, le filtre spectral (ou les filtres spectraux) définit le domaine spectral de la mesure et le détecteur transforme le signal physique en informations utilisables pour l'utilisateur. Différents objectifs sont poursuivis par les satellites, certains fournissent une vision globale du territoire (SPOT Végétation,...) ; ils visent l'obtention d'images couvrant la plus grande superficie possible, sans faire de la résolution spatiale un paramètre contraignant. Ces satellites ont une très haute résolution temporelle, ce qui est très intéressant pour le suivi de l'environnement. D'autres analysent le territoire de manière précise (SPOT HVR, IKONOS,...) ; l'espace étudié est beaucoup plus petit et la résolution spatiale nettement meilleure. Dans ce travail, il s'agira de traiter des images à très haute résolution spatiale du cinquième Satellite Pour l'Observation de la Terre (SPOT 5).

## 1.3 Les images satellitaires SPOT

Elles sont issues des satellites SPOT (Satellites Pour l'Observation de la Terre), destinées à l'observation du sol terrestre. Les caractéristiques de ces satellites définissent la résolution et le mode spectral des images. Il faut savoir que le système SPOT est opérationnel depuis février 1986, et qu'il existe plusieurs générations de satellites avec des caractéristiques différentes. Ainsi, en 1986 est lancé le premier satellite. SPOT2 l'a rejoint en orbite en janvier 1990, suivi de SPOT3 en septembre 1993, de SPOT4 en mars 1998 et enfin de SPOT5 en mai 2002. Il est possible d'obtenir des images de résolution allant de 20 mètres (pour les images multispectrales de SPOT1, 2, 3 et 4) à 2,5 mètres (pour les images panchromatiques de SPOT5) [8].

Le principal avantage des images SPOT est leur disponibilité depuis 1986 avec des capteurs similaires. Cela permet ainsi d'analyser l'évolution de certains phénomènes dans le temps.

### 1.3.1 SPOT 5

Le 4 mai 2002, une fusée Ariane 4 a lancé SPOT 5 (figure 1.3). Les appareils emportés par SPOT 5 sont repris, en comparaison avec les satellites anciens de la famille SPOT donnant la possibilité de prendre des données obliquement, une même région peut ainsi être observée par un même satellite environ tous les 4 jours. Les données satellites envoyées par SPOT 5 sont de très haute résolution spatiale, et ont ouvert la porte à un grand nombre de nouvelles applications. Cependant, cette grande quantité d'informations pose des problèmes de stockage, de transmission et de traitement.

Il diffère des précédents satellites SPOT par une meilleure résolution de prise de vue des capteurs haute résolution visible et proche infra rouge puisque les deux instruments jumeaux acquièrent des images multi spectrales avec une résolution de 10 m. La résolution de la bande spectrale Panchromatique (totalité du visible) passe de 10 à 5m. Seul le canal Moyen infrarouge garde une résolution de 20 m.

SPOT 5 est aussi doté d'un système stéréoscopique appelé HRS (Haute Résolution Stéréoscopique) permettant une prise de vue 20° avant et 20° arrière quasi-simultanée de 600km le long de la trace du satellite sur 120 km de large. Cette stéréoscopie permet de construire des modèles numériques de terrain. et deux instruments HRG sont dérivés du capteur HRVIR de SPOT 4. Les bandes spectrales sont identiques, mais la résolution spatiale est meilleure (10 m) dans les trois bandes B1, B2 et B3.

Par ailleurs SPOT 5 est équipé du capteur Végétation 2, à grand champ, qui a une résolution de 1Km pour une fauchée de 2400km. Ce large champ permet une couverture journalière de la surface terrestre et de constituer régulièrement un état de l'activité végétale du globe.



Figure 1.3 Satellite SPOT 5

### 1.3.2 Affichage des images

On appelle composition colorée en fausse couleur, un nouveau codage on affecte le canal XS1 la couleur rouge, on affecte au canal XS2 la couleur verte et enfin au canal XS3 la couleur rouge, voir le tableau 1.1.

Tableau 1.1 Composition colorée en fausses couleurs

Canal	Longueur d'onde	Couleur affectée
XS 1	Vert	bleu
XS 2	rouge	vert
XS 3	proche infrarouge	rouge

Une image multispectrale est une image obtenue à partir de capteurs opérant dans plusieurs bandes spectrales à la fois [9], figure 1.2.

Tableau 1.2 Les bandes de l'image SPOT multispectrale

Image	Bande	Absorption	Longueur d'onde ( $\mu\text{m}$ )	Résolution spatiale (m)
SPOT 2 (VHR)	XS1	Vert	0,50 - 0,59	20
	XS2	Rouge	0,61 - 0,68	20
	XS3	Proche infrarouge	0,78 - 0,89	20
	PAN	Panchromatique	0,50 - 0,73	10
SPOT (HVR)	B1	Vert	0,50 - 0,59	20
	B2	Rouge	0,61 - 0,68	20
	B3	Proche infrarouge	0,79 - 0,89	20
	B4	Moyen Infrarouge	1,58 - 1,75	20
	PAN	Panchromatique	0,61 - 0,68	10
SPOT5 (HRG)	B1	Vert	0,50 - 0,59	10
	B2	Rouge	0,61 - 0,68	10
	B3	Proche infrarouge	0,79 - 0,89	10
	SWIR	Moyen infrarouge	1,58 - 1,75	20
	PAN	Panchromatique	0,51 - 0,73	2.5

#### 1.4 Echelles de traitement de données et choix des canaux

Le développement des technologies a permis d'obtenir des images à très haute résolution, ce qui a provoqué un changement dans la manière de traiter l'information des données satellites. Le nombre de pixels mixtes, contenant plusieurs objets ou parties d'objets, a fortement diminué, ce qui facilite grandement l'interprétation des signatures spectrales. Ces images à très haute

résolution remettent même en question la pertinence de l'échelle d'analyse, qui ne s'assimile plus nécessairement à celle du pixel [10].

Une nouvelle méthode a été élaborée pour traiter au mieux cette nouvelle information : la classification contextuelle ou segmentation. Elle intègre les informations contextuelles et spatiales. Les pixels sont toujours analysés sur base de leurs propriétés spectrales mais aussi sur base des relations qu'ils entretiennent avec leurs voisins. L'image est divisée en plusieurs régions, dont la taille est supérieure à celle du pixel, les critères de regroupement étant la proximité, la répétitivité, la superficie, la forme, une certaine homogénéité de texture, [11-13]. Pour faciliter et optimiser la classification il est important de sélectionner les bandes spectrales les plus intéressantes, c'est à dire les plus discriminantes. Pour cela, il faut connaître le comportement spectral des éléments à distinguer. La réflectance d'un sol nu, par exemple, est de manière générale peu influencée par la longueur d'onde, par contre le taux d'humidité, la concentration en matière organique, le pourcentage de fer et la texture ont une importance prépondérante. L'eau, quant à elle, présente une signature spectrale avec trois bandes d'absorption, 1,45 $\mu\text{m}$ , 1,9 $\mu\text{m}$ , 2,7 $\mu\text{m}$  ; ce qui se remarque dans la végétation (figure 1.3), plus ou moins fort en fonction de la concentration en eau dans les tissus foliaires. La signature spectrale de la végétation présente deux comportements totalement opposés dans le domaine du visible, plus particulièrement dans le rouge, et dans celui du PIR, la transition entre les deux se traduisant par une brusque augmentation de la réflectance.

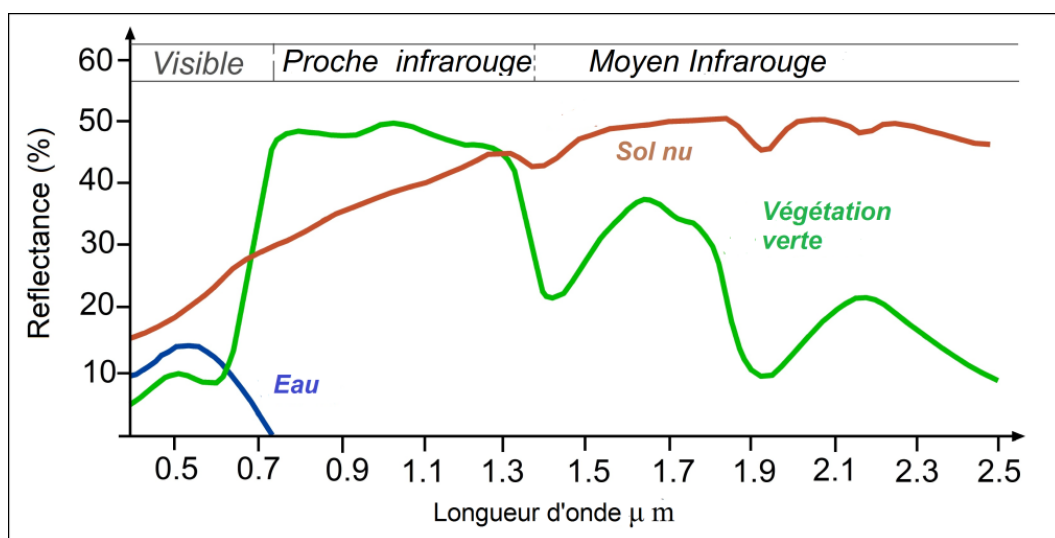


Figure 1.4 Spectre électromagnétique de la végétation chlorophyllienne

## **1.5 Conclusion**

La télédétection est un outil proche des besoins des utilisateurs dans des applications aussi diversifiées que l'agriculture, la cartographie, l'urbanisme, la gestion des forêts, la gestion des risques naturels, la géologie, l'exploration des ressources en eau, l'étude côtière et océanique, le contrôle et la surveillance de l'environnement. Dans ce travail, une image acquise par SPOT 5 sera utilisée pour l'extraction des zones bâties de la région d'el bordj (Laghouat, Algérie).

***Classification des Images  
Satellites***

## 2.1 Introduction

Les données de télédétection peuvent être analysées pour extraire les informations thématiques utiles. La classification multi spectrale est l'une des méthodes les plus souvent utilisées pour l'extraction de ces informations. Cette procédure suppose que les images d'une région géographique donnée sont réparties dans différents spectres électromagnétiques. La classification multispectrale peut être effectuée en utilisant une variété d'algorithmes comprenant les méthodes supervisées et non supervisées.

## 2.2 Définition de la classification

L'information apportée par la classification se situe en effet au niveau sémantique il ne s'agit pas d'atteindre un résultat vrai ou faux, probable ou improbable, mais seulement profitable ou non profitable [15].

En télédétection, les canaux spectraux relatifs à une image tel que LANDSAT TM1, TM3, TM4 permettent de donner une description multispectrale d'un élément au sol. Théoriquement, chaque objet possède une définition multi spectrale pour  $n$  canaux spectraux (Figure 2.1) appelée signature spectral ( $I_1(x, y)$ ,  $I_2(x, y)$ , ...,  $I_n(x, y)$ ). C'est à partir de ces signatures que s'opère la classification d'image satellitaire

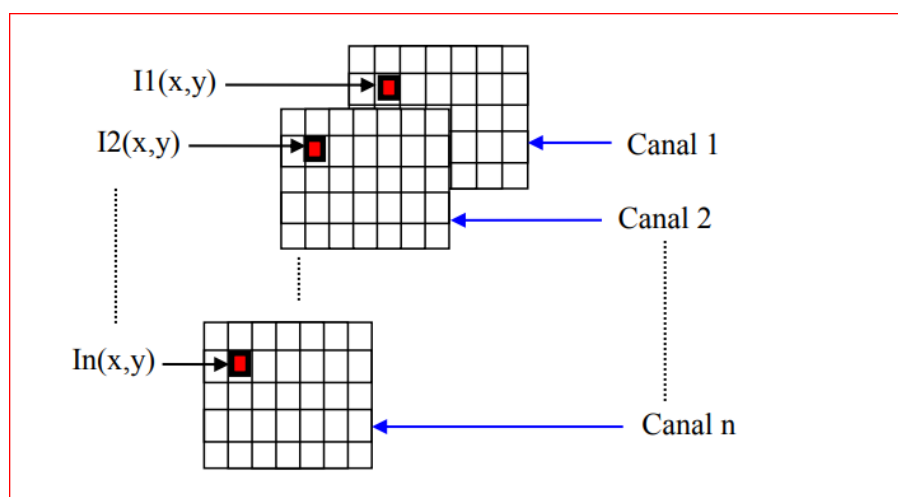


Figure 2.1 Définition multispectrale d'un objet

## 2.3 Le principe de la classification

La classification consiste à mettre ensemble les individus qui se ressemblent et de séparer ceux qui diffèrent selon une mesure de distance ou de dissemblance entre les objets. Elle a pour but de minimiser l'information sur les individus par les partitions qui les englobent et que porteront

l'information. Au lieu de parler de chaque individu à l'écart, on parle de la classe qui généralise toute l'information de ceux qui lui appartiennent.

L'objectif général des classifications est d'interpréter les informations spectrales en classe thématiques c'est à dire, à partir des données (images) provenant des capteurs, on fait un partitionnement de l'image en classe thématique, ce qui est aussi appelé **zonage**. On a plusieurs stratégies de zonage tel que [16]:

- L'approche par pixel (analyse multi spectrale).
- L'approche par zone (détection de contours).
- L'approche par objet (analyse morphologique).

## 2.4 Eléments de la classification

### 2.4.1 La classe

Dans le contexte de la télédétection, une classe est un ensemble de pixels possèdent des caractéristiques semblable. On peut distinguer les classes thématiques, qui sont des catégories propres au thème traités : mur, forêt, sol nu etc..., et les classes spectrales qui sont constituées par des pixels de valeurs semblables. Les classes spectrales sont le plus souvent définies à l'aide de paramètres statistiques tels que la valeur moyenne, l'écart type, etc...

### 2.4.2 La ressemblance

Pour déterminer la ressemblance d'un pixel avec une classe, on utilise les critères de distance ou de probabilité. Deux pixels se ressemblent au mieux si la distance entre eux est minimale.

### 2.4.3 L'appartenance

Les critères d'attribution d'un pixel à une classe donnée sont établis par une fonction discriminante qui décidera de l'appartenance d'un pixel à une classe. Il existe deux types de classes :

- Les classes d'informations : c'est ce que l'analyse tente d'identifier sur les images.
- Les classes spectrales : c'est le regroupement de pixel ayant les mêmes caractéristiques ou presque par exemple la valeur de densité, dans les différentes bandes spectrales des données.

L'objectif de la classification est de faire la correspondance entre les classes spectrales et les classes d'informations.

## 2.5 Les méthodes de classification

Les méthodes de classification peuvent être schématiquement regroupées en deux grandes catégories, selon que l'on dispose ou non de prototypes. En distinguant deux classes:

- Les méthodes non supervisées (non dirigées).
- Les méthodes supervisées (dirigées).

### 2.5.1 Classification non supervisée

Dans une classification non supervisée, l'identité des types de couverture du sol devant constituer les classes d'information n'est pas généralement connue à priori et contrairement à la classification supervisée, elle nécessite une quantité minimale d'entrée initiale de part d'analyse. Avec cette méthode des opérations numériques sont effectuées pour déterminer les regroupements naturels des propriétés spectrales des pixels dans l'espace multispectrale des caractéristiques [17].

#### 2.5.1.1 Méthodes de classification non supervisées

Parmi les algorithmes de classification non-supervisée les plus utilisés nous pouvons citer :

- **La méthode des modes de l'histogramme**

Un histogramme monodimensionnel d'une image est une représentation graphique ayant en abscisses des valeurs de niveau de gris, et en ordonnées le nombre de pixels associé à chaque valeur de niveau de gris. Le mode d'un histogramme est un maximum local de cet histogramme et une vallée est un minimum global. Le mode d'un histogramme indique un regroupement de pixels et il sert à détecter des classes. L'algorithme de classification par mode de l'histogramme monodimensionnel se résume par les étapes suivantes :

- 1- Construire l'histogramme de l'image;
- 2- Détecter K maximums locaux du l'histogramme (K est le nombre de classes souhaité).
- 3- Regrouper les pixels de l'image selon le critère de distance minimale par rapport aux différents centres de classes. Chaque pixel est affecté à la classe dont le centre est le plus proche.
- 4- Attribuer une même couleur aux pixels appartenant à la même classe et afficher l'image résultat.

On peut aussi réaliser une classification multi-bande en réalisant un histogramme bidimensionnel. Dans ce cas, on compte le nombre de pixels associé à chaque paire de

niveaux de gris. Lorsque ceci est fait, on utilise le même algorithme que celui de modes de l'histogramme monodimensionnel

- **La méthode des centres mobiles ou ISODATA**

Une méthode de segmentation utilisée est la méthode Itérative Self-Organizing Data Analysis Technique (ISODATA). La méthode ISODATA représente un ensemble compréhensible de procédures heuristiques qui ont été incorporées dans un algorithme de classification itératif. La plupart des étapes incorporées dans l'algorithme sont le résultat des expériences accumulées à travers des expérimentations. L'algorithme ISODATA est auto-organisateur parce qu'il nécessite relativement très peu d'entrées de la part de l'analyste [17,18].

### 2.5.2 Classification supervisée

La classification supervisée est un traitement avec connaissance à priori des thèmes présents dans les observations, l'utilisateur définit des régions qui sont des groupes d'objets qu'il souhaite affecter à des classes différentes dans la population. Ce type de classification est utilisé pour convertir les données de télédétection en une carte thématique, il comporte en général trois étapes [17] (voir figure 2.2):

1. **L'étape d'entraînement** aux cours de laquelle des pixels de classe connue sont identifiés et caractérisés pour former les statistiques d'entraînement servant à décrire les classes.
2. **L'étape d'allocation** des classes elle consiste à affecter chaque pixel de l'image à la classe avec laquelle il a la plus grande vraisemblance.
3. **L'étape de vérification** : évalue la quantité de la classification.




Figure 2.2 Classification dirigée: sites d'entraînement (à gauche) et l'image complètement classifiée (à droite)

### 2.5.2.1 Méthodes de classification supervisées

Le choix d'une méthode de classification particulière ou d'une règle de décision dépend de la nature des données d'entrées et de la classification désirée. Les algorithmes de la classification paramétriques supposent que les données des classes d'entraînement ont une distribution particulière, généralement gaussienne, par contre les algorithmes de classifications non paramétriques ne font aucune hypothèse sur la distribution des données d'entraînement.

Parmi les algorithmes de classification supervisée les plus utilisés, nous pouvons citer [19]:

- **La règle de décision des parallélépipèdes**

Cette règle est largement utilisée. Elle est basée sur une logique booléenne. Des données d'entraînement dans  $n$  bandes spectrales sont utilisées pour effectuer la classification. Pour chaque classe  $C$  on calcule le vecteur moyen,  $\mu_c$ , avec :

$c = 1 \dots m$  : représente le nombre ou numéro de classe

$k = 1 \dots n$  : représente le nombre de bandes.

$$\mu_c = \begin{pmatrix} \mu_{c1} \\ \cdot \\ \cdot \\ \mu_{cn} \end{pmatrix}$$

Avec  $\mu_{ck}$  représente le niveau de gris moyen des pixels de la classe  $C$  dans la bande  $k$ ,  $S_{ck}$  est l'écart type des données d'entraînement de la classe  $C$  dans la bande  $k$ . si on utilise un seuil par exemple égale à  $S_{ck}$  par exemple, l'algorithme des parallélépipède affecter un pixel de vecteur de mesure  $X_i$  à la classe  $C$ , tel que :

$$X_i = \begin{pmatrix} V_{i1} \\ \cdot \\ \cdot \\ V_{in} \end{pmatrix}$$

$V_i$  : les composants d'un pixel à classifier, par exemple les composants d'un pixel pour une image LANDSAT sont les valeurs radiométriques sur les différents canaux (TM1, TM2,.....). Cette affectation est bonne, si et seulement si l'équation suivante est satisfaite :

$$\mu_{ck} - S_{ck} < V_{ik} < \mu_{ck} + S_{ck} \quad \forall k \in \{1, n\} \quad (2.1)$$

Par conséquent, si les frontières de décision inférieur et supérieur sont définies respectivement par :

$$L_{ck} = \mu_{ck} - S_{ck} \text{ et } H_{ck} = \mu_{ck} + S_{ck}$$

La règle de décision de parallélépipède devient celle qui est exprimée par la relation (2.2).

$$L_{ck} < V_{ik} < H_{ck} \quad \forall k \text{ alors } X_i \in C \quad (2.2)$$

Ces règles de décision forment un parallélépipède multidimensionnel dans l'espace des caractéristiques. Si la valeur du pixel comprise entre la borne inférieure et la borne supérieure pour tous les  $n$  bandes évaluées pour une classe donnée, il est affecté à cette classe. Dans le cas contraire, il est affecté à une catégorie non classifiée. L'algorithme de parallélépipède est une méthode de classification simple et efficace [16].

- **La classification par la méthode de la distance minimale**

Cette méthode est simple, elle peut produire des classifications comparable à celle produites par d'autre algorithme plus coûteux en calcul, comme l'algorithme du maximum de vraisemblance. A l'instar de l'algorithme du parallélépipède, la méthode de la distance minimale nécessite que l'utilisateur fournisse les vecteurs moyens de toutes les classes à partir des données d'apprentissage [17,18]. Pour effectuer une classification par distance minimale, un programme doit calculer la distance euclidienne  $D_{ci}$  (équation (2.3)) par rapport à chaque vecteur moyen  $\mu_{ck}$  pour chaque pixel inconnu  $X_i$

$\mu_{ck}$ : la moyen de la classe C dans la bande k.

$V_{ik}$ : la valeur du pixel inconnu  $X_i$  dans la bande k.

$D_{cj}$  : la règle de la décision minimale.

$n$  : représente le nombre de bandes.

$$d_{ci} = \sqrt{\sum_{k=1}^n (V_{ik} - \mu_{ck})^2} \quad (2.3)$$

La règle de décision de la distance minimale aux moyennes s'exprime alors par la relation suivante

$$D_{cj} = \min_c \{d_{ci}\} \text{ alors } X_i \in C \quad (2.4)$$

- **La classification par la méthode des k plus proches voisins**

Cette méthode n'a pas besoin de données déduites de la phase d'apprentissage. Pour commencer on doit définir une distance ou métrique et un prototype de chaque classe. Dans la base d'apprentissage les différentes classes sont stockées en mémoire.

A l'arrivée d'un nouveau pixel  $X_i$  à classer, l'algorithme calcule la distance entre  $X_i$  et les prototypes des différentes classes, puis détermine la fréquence d'apparition  $f_{ck}$  des pixels de chaque classe  $C$  parmi les  $k$  plus proches voisins du pixel considéré. La règle de décision des  $k$  plus proches voisins s'exprime alors par la relation suivante :

$$f_{ck} = \max_c \{f_{ck}\} \text{ alors } X_i \in C \quad (2.5)$$

Le problème majeur de cette méthode est l'initialisation du nombre  $k$ . pratiquement on choisie  $k = r \times \sqrt{n}$  Où  $r$  un constante approprié (typiquement  $r=1$ ) et  $n$  est le nombre de données d'entraînement. Lorsque  $k=1$  cette règle de décision correspond à la règle de classification de distance minimale. Le principal inconvénient de cette règle de décision c'est qu'elle prend un temps de calcul très long.

- **Méthode de maximum de vraisemblance**

La signature spectrale d'objets est caractérisée par un certain nombre de signatures plus ou moins fréquentes, il peut être opportun de traiter celle-ci à partir des lois de probabilité.

Cette approche permet d'effectuer une signature spectrale suivant des règles de décision où les risques d'erreur seront minimisés par le calcul des probabilités.

BAYES a défini un critère général qui permet d'optimiser la probabilité de succès dans la segmentation de l'espace spectral :

Si :  $P(C_i)$  est la probabilité d'occurrence de la classe  $i$  ;  $P(X \setminus C_i)$  la probabilité d'observation conditionnelle du vecteur  $X$ , compte tenu du fait que  $C_i$  soit retenu à priori et  $P(X)$  la probabilité que le vecteur  $X$  survient. Alors :

La probabilité conditionnelle d'observation de la classe  $i$ , compte tenu du fait que le vecteur  $X$  soit retenue à priori est :

$$P(C_i \setminus X) = \frac{P(X \setminus C_i)P(C_i)}{P(X)} \quad (2.6)$$

Il devient facile de prévoir qu'un pixel sera associé à la classe numéro  $i$ , si et seulement si, pour tous les  $j$  :

$$P(C_i \setminus X) > P(C_j \setminus X) \quad (2.7)$$

- **Méthodes géométrique**

Cette approche consiste à partitionner l'espace de représentation des observations en domaines. Ces domaines sont délimités par des surfaces. Beaucoup de surfaces de séparation peuvent être envisagées, les plus simples correspondent au cas linéaire. D'autres surfaces de séparations d'ordre supérieur à 1 peuvent également être utilisées telles que les hyper sphères, les paraboloïdes, les ellipsoïdes, etc. les possibilités sont supérieures à celle d'un classifieur linéaire, mais le défaut de cette démarche est que le nombre de coefficients à ajuster, dépend directement de la dimension de l'espace des observations.

C'est la raison pour laquelle, les surfaces de type hyperplan sont souvent utilisées. Dans ce cas les techniques utilisées consistent à déterminer les équations mathématiques de ces hyperplans. Ensuite, à partir de ces équations, on construit une série de règles permettant de déterminer la classe d'appartenance de toute observation inconnue. Ainsi, l'on obtient des règles de décision similaire à celle-ci :

$$\text{Si } d_k(X) > d_{k'}(X) \forall k \neq k' \text{ alors } X \in C_k$$

Où  $d_k(X)$  est appelée fonction discriminante

L'équation déterminante l'hyperplan de séparation entre le domaine  $D_k$  et le domaine  $D_{k'}$  s'exprime par :

$$d_k(X) = d_{k'}(X) \quad (2.8)$$

Le classifieur assignera alors une observation inconnue  $X$ , en identifiant la domaine  $D_k$  de l'espace dans le quel se trouve cette observation [17]. Ainsi on aura :

$$X \in D_k \Leftrightarrow X \in C_k$$

## 2.6 Historique sur K-moyennes (K-means)

Le terme "K-means" a d'abord été utilisé par James MacQueen en 1967, Bien que l'idée remonte à Hugo Steinhaus en 1956. L'algorithme standard a été proposé par Stuart Lloyd en 1957 comme une technique d'impulsions Code Modulation, même si elle ne fut publiée qu'en 1982 [19].

### 2.6.1 Présentation de K-means

L'algorithme K-means, également appelé algorithme des nuées dynamiques, est l'algorithme de clustering le plus connu et le plus utilisé du fait de sa simplicité de mise en œuvre. Il partitionne les données d'une image en K clusters. L'algorithme renvoie une partition des données, dans

laquelle les objets à l'intérieur de chaque cluster sont aussi proches que possible les uns des autres et aussi loin que possible des objets des autres clusters (figure 2.3). Le résultat est un ensemble de clusters compacts et séparés, si la valeur  $K$  du nombre du cluster est bien choisie au départ [20].




Figure 2.3 Principe de fonctionnement général de K-means.

Le principe des K-means est de minimiser la fonction objective de manière itérative:

$$J(x, c) = \sum_{i=1}^N \sum_{K=1}^C \|x_i - c_k\|^2 \quad (2.9)$$

- $K$  est le nombre de classe.
- $N$  est le nombre de données.
- $c_k$  est le centre de classe  $K$ .
- $\| \cdot \|$ : est la norme Euclidienne qui mesure la similarité entre un pixel est un autre

### 2.6.2 K-means et la segmentation d'images

Les méthodes de classification (*clustering*) issues de l'analyse de données permettent de regrouper des objets possédant des propriétés similaires. Elles constituent donc approche naturelle pour réaliser une segmentation d'image. La méthode des K-means a été très utilisée, d'une part pour sa simplicité de mise en œuvre et d'autre part car elle peut fournir une bonne approximation de la segmentation recherchée.

Néanmoins cette méthode souffre d'un défaut qui a son importance en segmentation d'images : elle introduit des discontinuités spatiales assez fortes aux frontières des classes.

Des méthodes de régularisation sont donc généralement employées pour renforcer la connexité et ainsi réduire le nombre de composantes connexes de chaque classe [22].

Les principales étapes de l'algorithme K-means sont [20] (figure 2.4):

1. Choix aléatoire de la position initiale des  $K$  clusters.
2. (Ré-) Affecter les objets à un cluster suivant un critère de minimisation des distances (généralement selon une mesure de distance euclidienne).

3. Une fois tous les objets placés, recalculer les  $K$  centroïdes.
4. Répéter les étapes 2 et 3 jusqu'à ce que plus qu'aucune réaffectation ne soit faite.




Figure 2.4 Démonstration des quatre étapes de K-means avec ( $K=3$ ).

Cette méthode présente des inconvénients majeurs du fait que le nombre de clusters doit être choisi à l'initialisation. La classification finale est étroitement liée au nombre de classes initial.

### 2.6.3 Intérêt et limitation de la méthode K-means

- **Intérêt** : Cet algorithme est très populaire car extrêmement rapide en pratique. En effet, le nombre d'itérations est typiquement inférieur au nombre de points.
- **Limitation**: L'utilisateur doit choisir le nombre  $K$  de classes et il n'y a pas de critère unique pour déterminer le meilleur nombre de classes ; Lorsque les classes ne sont pas bien séparées, les K-means tendent à trouver uniquement des classes "sphériques", de même effectif et de même volume. Plusieurs initialisations peuvent conduire à plusieurs partitions très différentes dans leur composition. En termes de performance, cet algorithme ne garantit pas un optimum global [23].

### 2.6.4 Domaines d'applications

L'algorithme K-means clustering est couramment utilisé en vision par ordinateur comme une forme de segmentation d'image. Les résultats de la segmentation sont utilisés pour faciliter la détection des frontières et la reconnaissance d'objets. Dans ce contexte, la distance euclidienne standard est généralement insuffisante dans la formation des clusters. Au lieu de cela, une mesure de distance pondérée en utilisant les coordonnées des pixels, de couleur **RGB** pixel et / ou l'intensité et la texture de l'image est couramment utilisé.

## 2.7 Conclusion

La classification apparaît en cours trop souvent comme un arsenal des méthodes qui n'ont en commun que leur finalité et qui fait appel à autant de notions mathématiques et de concepts scientifiques.

Selon le nombre d'observations par classe et la dimension des données, selon la possibilité d'utiliser un modèle paramétrique et compte tenu des informations dont il dispose a priori, l'analyste doit choisir une stratégie parmi un ensemble de méthodes très diverses et souvent peu comparables, chacune ayant ses points forts et ses points faibles .

***Les champs de Markov cachés***

### 3.1 Introduction

Le chapitre précédent a permis d'évoquer la classification des images satellitaire. Ce chapitre est consacré au formalisme Markovien, son objective est de présenter brièvement le domaine des champs de Markov et leur application en traitement d'images.

### 3.2 Historique

Les champs de Markov sont utilisés depuis plus d'une trentaine d'années en traitement d'images et font désormais partie des techniques de base de cette discipline. Nés dans le cadre de la physique statistique pour étudier les phénomènes de transition de phase [25], ils sont rapidement appliqués aux réseaux bidimensionnels que constituent les images. Les premiers modèles sont restreints par des contraintes de causalité [26] et donc limités jusqu'à l'article fondateur de Geman en 84 [27] qui ouvre réellement leur utilisation en traitement d'images. Cette utilisation ira croissant avec les années. Elle donnera lieu à de nombreuses recherches sur les problèmes que suscite leur utilisation (calcul des paramètres des modèles, techniques de simulation et de recherche de solutions rapides, etc.). Parallèlement, des alternatives aux champs de Markov comme les chaînes de Markov et les arbres de Markov seront développées, leur intérêt principal résidant dans la réduction drastique du temps de calcul et les méthodes d'estimation de paramètres associées. A côté de ces travaux toujours d'actualité, se sont ouvertes de nouvelles recherches dédiées à des tâches de plus haut niveau et visant à l'interprétation des images, notamment dans le cadre de la géométrie stochastique.

### 3.3 Champ de Markov et distribution de Gibbs

La théorie des champs de Markov est une branche de la théorie des probabilités pour l'analyse des dépendances spatiales de phénomènes physiques. Dans cette section nous commençons par rappeler quelques notions de base, tel le système de voisinage et clique. Ensuite, nous présentons la définition mathématique des champs de Markov et distribution de Gibbs, ainsi que l'équivalence entre champs de Markov et champs de Gibbs (théorème de Hammersley – Clifford).

Les champs de Markov sont des outils probabilistes assez largement utilisés en traitement d'images. Leur intérêt majeur est de pouvoir modéliser les dépendances spatiales des variables aléatoires, dont les réalisations modélisent les quantités observées ou recherchées, de façon relativement simple et se prêtant bien aux divers traitements. Divers modèles fondés sur les champs markoviens ont été proposés, parmi lesquels les champs de Markov cachés (CMC), très utilisés en segmentation d'images [27].

Il est important d'abord de préciser que la modélisation par les champs de Markov cachés n'est pas en elle-même une méthode de segmentation, mais un modèle statistique qui peut être employé dans des méthodes de segmentation. On peut noter aussi que les variables cachées n'ont pas, à priori d'existence physique dans le phénomène observé; mais, elles sont avant tout utilisées pour créer des modèles flexibles.

### 3.3.1 Système de voisinage et clique

- **Système de voisinage**

En analyse d'images, l'image est représentée par une grille :

$S = \{S = (i, j); 0 \leq i \leq n - 1; 0 \leq j \leq m - 1\}$  rectangulaire finie bidimensionnelle

de taille  $n \times m$  contenant un ensemble de "sites"  $s \in S$ , appelés également "pixels". On appelle un système de voisinages toute famille.

$V = (V_s)_{s \in S}$  vérifiant les propriétés suivantes :

- ◆  $s \notin V_s$ , c.à.d. un site n'est pas voisin à lui-même ;
- ◆  $s \in V_t \Leftrightarrow t \in V_s$  qui signifie que la relation de voisinage est symétrique.

A titre d'exemple, l'ensemble des "voisins" d'un site  $s$  peut être défini comme un ensemble de sites situés dans un rayon  $r$  :  $V_s = \{t \in S / d(s, t) \leq r, t \neq s\}$ , où  $d(s, t)$  est la distance euclidienne entre le pixel  $s$  et le pixel  $t$ , et  $r$  est à valeur dans l'ensemble des entiers [28] Notons que les systèmes de voisinage les plus usuels, représentés en figure 3.1, sont :

Système "4 - connexité", également appelé voisinage du premier ordre ;

Système "8 - connexité", également appelé voisinage du second ordre.

A partir d'un système de voisinage, un système de clique est déduit.

- **Clique**

Un sous ensemble  $c$  de  $S$  est appelé clique relative au système de voisinage  $V$ , si c'est un singleton ou si tous les sites distincts de  $c$  sont voisins. Une clique est dite d'ordre  $P$ , si elle contient  $P$  éléments, en d'autres termes, l'ordre d'une clique est par définition son cardinal. Figure 3.1 illustre la notion de cliques dans le cas de voisinage en 4-connexité et en 8-connexité. On notera  $C$  l'ensemble des cliques associées à un système de voisinage.

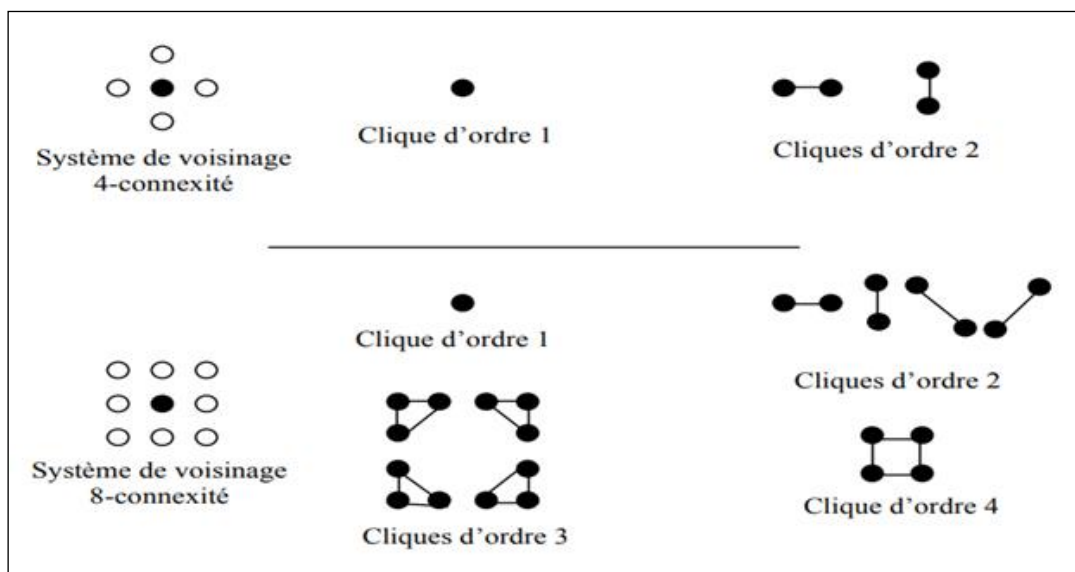


Figure 3.1 Cliques associées à un système de voisinage en 4-connextité et en 8-connextité

### 3.3.2 Chaîne de Markov

Soit  $S$  un ensemble de pixels et  $\mathbf{X} = (X_s)_{s \in S}$  une famille de variables aléatoires, définie sur, où chaque  $X_s$  est à valeurs dans un ensemble fini de classes  $\Omega = \{\omega_1 \dots \omega_k\}$ . Une telle famille sera dans la suite appelée "champ aléatoire". Soit un système de voisinage. On notera par la même lettre  $p$  les diverses lois de probabilité liées à  $X$ .

On dit qu'un champ  $X$  est un champ de Markov relativement à  $V$ , si et seulement si les deux propriétés suivantes sont vérifiées [28]:

- Positivité:

$$\forall x \in \Omega^{\text{card}(S)}, p(x) > 0 \text{ (contrainte de positivité)} \quad (3.1)$$

- Markovianité:

$$p(x_s | x_t, t \neq s) = p(x_s | x_t, t \in V_s) \quad (3.2)$$

La propriété (3.2) signifie que la probabilité en un site  $s$  conditionnelle à tous les autres sites n'est fonction que de la configuration du voisinage du site considéré. En d'autres termes, la probabilité d'apparition d'une classe donnée en un site  $s$  conditionnellement au reste du champ, est égale à sa probabilité d'apparition connaissant simplement ses voisins.

Notons que tous les champs positifs aléatoires peuvent être considérés comme markoviens, à condition de choisir un système de voisinage suffisamment grand [28]. Cependant, l'intérêt de restreindre le voisinage est de permettre des temps de calculs exploitables.

### 3.3.3 Champ de Gibbs

Soit  $S$  un ensemble de pixels muni d'un système de voisinage  $V$ , et soit  $C$  l'ensemble des cliques  $c$  associées à  $V$ . Le champ  $X$  est un champ de Gibbs (CG), si et seulement si sa loi est définie par :

$$p(X = x) = \frac{1}{Z} \exp^{-U(x)} \quad (3.3)$$

Avec :

$$U(x) = \sum_{c \in C} \phi_c(x_c) \quad (3.4)$$

Qui est dite "fonction énergie", et :

$$Z = \sum_{X \in \Omega^{\text{card}(S)}} \exp(-U(x)) \quad (3.5)$$

Une telle loi est dite une "distribution de Gibbs". Notons que  $\phi_c$  sont des applications de  $\Omega^{\text{card}(c)}$  dans  $R$  appelées "fonction potentiel" avec  $x_c$  la restriction de  $x$  à  $c$  et  $Z$  est une constante de normalisation, également appelée "fonction de partition" qui fait de  $p(x)$  une probabilité. Etant donné que cette constante est une somme sur l'ensemble de toutes les configurations possibles du champ  $X$ , son calcul est dans la pratique généralement impossible. Par exemple, pour une image binaire ( $\text{Card}(\Omega) = 2$ ) de taille  $256 \times 256$  pixels, le calcul de  $Z$  nécessite une somme sur  $2^{256 \times 256}$  configurations possibles, ce qui est rédhibitoire

### 3.4 Echantillonneur de Gibbs

Cet algorithme, proposé par Geman et Geman [26], repose sur la construction itérative d'une suite d'images. A la convergence, les images construites sont des réalisations tirées selon la loi de Gibbs globale selon l'algorithme suivant :

Partant de l'image à l'itération  $(n - 1)$ , construction de l'image à l'itération  $n$  se fait par mises à jour successives des sites de l'image.

A l'étape  $n$  :

- choix d'un site  $s$ ;
- au site  $s$ , selon la configuration des voisins  $V_s$  pour l'image  $x^{(n-1)}$  calcul de la probabilité conditionnelle locale:

$$P(X_s = x_s / V_s) = \frac{\exp(-U_s(x_s / V_s))}{\sum_{\xi \in E} \exp(-U_s(\xi / V_s))}; \quad (3.6)$$

- mise à jour du site  $s$  par tirage aléatoire selon la loi  $P(X_s = x_s/V_s)$ .
- L'algorithme converge après un grand nombre d'itérations ou lorsque le nombre de changements est faible [2].

### 3.5 Modèle markovien caché pour la segmentation d'images

On considère deux champs aléatoires:  $X = (X_s)$  et  $Y = (Y_s)$ , avec  $S$  l'ensemble des pixels, dans lesquels chaque variable aléatoire  $X_s$  est à valeurs dans l'ensemble fini de classes  $\Omega = \{\omega_1, \dots, \omega_k\}$  et chaque variable aléatoire  $Y_s$  est à valeurs dans l'ensemble des nombres réels  $R$ . En segmentation d'images, le problème est d'estimer le champ inobservable, ou "caché",  $X = x$  à partir du champ observé, ou "bruité",  $Y = y$ . Dans le modèle "Champ de Markov caché" (CMC) classique,  $X$  est de Markov et la forme du bruit (loi de  $Y$  conditionnelle à  $X$ ) est simple, ce qui implique la markovianité de la loi de  $X$  a posteriori (sa loi conditionnelle à  $Y$ ). Cette dernière markovianité permet alors de mettre en œuvre les différents traitements bayésiens développés dans la section (3.5). Dans les CMC les plus classiques, la loi du couple  $(X, Y)$  est donnée par:

$$p(x, y) = \gamma \exp(-\sum_{c \in C} \varphi_{c \in C}(X_c)) \prod_{s \in S} p(Y_s | X_s) \quad (3.7)$$

Avec  $\gamma$  est une fonction de partition et  $\varphi$  la fonction potentielle.

Cette loi est fonction d'un certain nombre de paramètres, qu'on appellera vecteur paramètre, constitué de paramètres d'interaction  $\alpha$  liés à la loi a priori  $p(x)$ , et de paramètres  $\eta$  liés à la loi conditionnelle  $p(y | x)$  (ou encore lié au "bruit"). La connaissance de  $\theta = (\alpha, \eta)$  est nécessaire aux divers traitements, d'où la nécessité de pouvoir l'estimer. A cet effet, diverses méthodes ont été développées, dont nous mentionnons brièvement dans ce qui suit, les plus connues.

### 3.6 Apprentissage

Apprentissage Les méthodes d'estimation des paramètres peuvent être divisées en deux grandes familles, lesquelles peuvent être, à leur tour, classées selon leurs niveaux de complexité :

#### 3.6.1 Apprentissage à données complètes

Dans l'apprentissage à données complètes, l'estimation des paramètres du modèle markovien se fait à partir de toutes les données, contenant la vérité terrain  $X = x$  et l'observation  $Y = y$ . Parmi les diverses techniques existantes d'estimation de  $\alpha$  à partir de  $\alpha$  à partir de  $x$ , citons : la méthode du gradient stochastique et la méthode des moindres carrés.

#### 3.6.2 Apprentissage à données incomplètes

De complexité supérieure au cas précédent, l'apprentissage à données incomplètes est très utile, souvent même indispensable dans les applications réelles. Ici, l'estimation est réalisée à partir de

données incomplètes  $Y = y$  et l'algorithme "Itérative Conditional Estimation" (ICE) proposé dans [30]. Etant donné que ces deux derniers nécessitent des estimateurs de  $\theta$  à partir de données complètes, les méthodes d'apprentissage à données complètes, citées ci-dessus, peuvent être utilisées.

Sachant que le vecteur paramètre  $\theta$  est constitué de paramètres  $\alpha$  liés à la loi a priori  $p(x)$  et de paramètres  $\eta$  liés à la loi conditionnelle, il est à noter que  $\alpha$  lui-même est généralement constitué de paramètres d'interactions  $\alpha_i$ , et de paramètres  $\beta_k$  associés aux singletons dont le rôle est de gérer les proportions de chaque classe de l'image. Par ailleurs, dans le cas de bruit blanc gaussien les paramètres  $\eta_k$  sont les moyennes  $\mu_k$  et variances  $\sigma_k^2$ .

## 3.7 Estimation bayésienne

### 3.7.1 Estimateur Recuit simulé

Elle repose sur l'idée d'introduire un paramètre de température et de simuler un recuit, elle est connue de nos jours, sous le nom de "l'algorithme du recuit simulé".

Cet algorithme itératif est associé à une décroissance de température. Le but est de rechercher une configuration qui maximise la distribution :

$$P_T(X = x) = \frac{1}{Z(T)} \exp\left(-\frac{U(x)}{T}\right) \quad (3.8)$$

i.e. rechercher une configuration à énergie minimale. L'idée consiste à simuler une suite de réalisations suivant la distribution (3.8), en faisant décroître la température au cours des itérations. Au départ, une température  $T$  élevée, permet d'effectuer des sauts d'énergie afin de ne pas se stabiliser dans des minima locaux. Autrement dit, l'algorithme autorise dans ce cas des passages dans des configurations qui font augmenter la fonction énergie  $U$ , ce qui permet d'éviter de rester bloqué dans des minima locaux. Plus tard, lorsque la température décroît, ces sauts d'énergie sont progressivement supprimés. Ainsi, la suite de réalisations évolue progressivement vers le minimum global. Le déroulement de l'algorithme est le suivant:

- Initialiser une première carte "image"  $x^0$  façon arbitraire ;
- Initialiser la température  $T^{(0)}$  avec une "valeur assez élevée"
- A chaque étape  $n$  :
  - Balayer l'ensemble des sites  $s \in S$ , et en chaque site  $s$  :
- Calculer les probabilités conditionnelles  $P_{T(x)}(x_s|x_V)$

- Effectuer un tirage aléatoire, dans l'ensemble  $\Omega$ , selon ces probabilités conditionnelles afin de sélectionner l'état (ou la classe) qui sera attribué à ce pixel (qui peut éventuellement être le même).
  - Décroître la température  $T^{(n)} = k * T^{(n-1)}$  ( $k \approx 0.99$ )
- Refaire l'étape  $n$  jusqu'à ce que le taux de changement devienne faible.

### Remarque

La convergence de l'algorithme du recuit simulé dépend du schéma d'évolution de la température. Cela peut nécessiter une décroissance relativement lente, auquel cas la température peut rester constante sur plusieurs itérations.

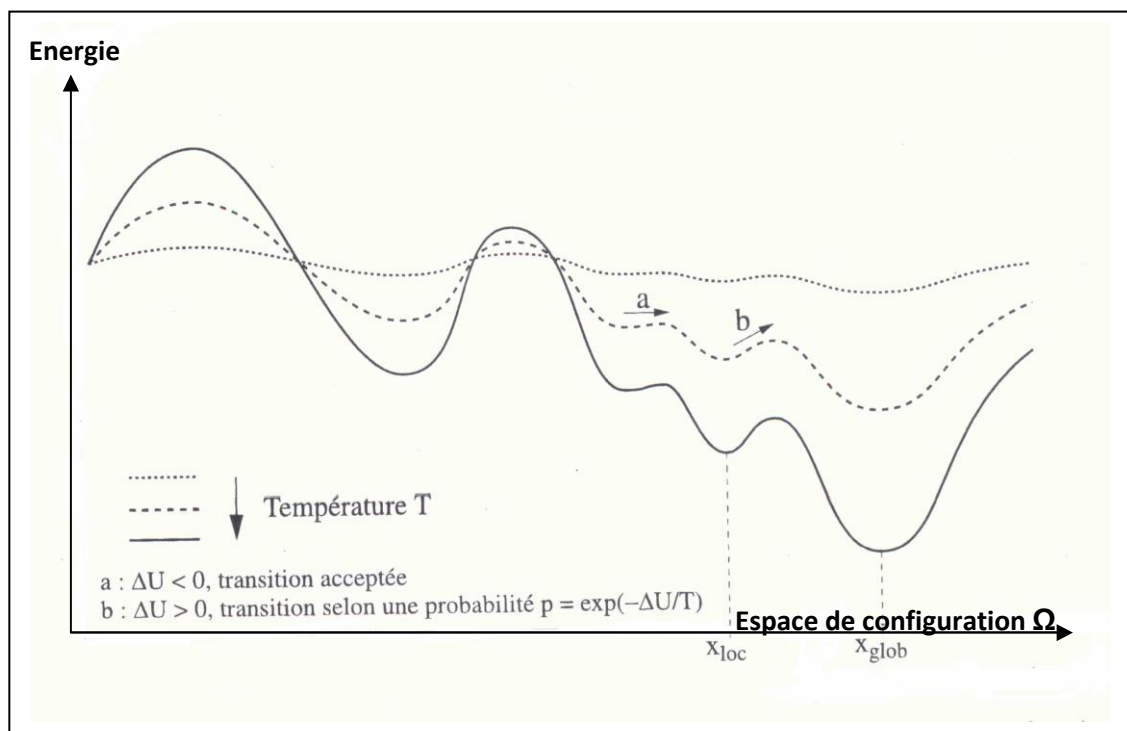


Figure 3.2 Evolution de la fonction d'énergie en fonction de la température

### 3.7.2 Estimateur des modes conditionnels

L'estimateur du mode conditionnel itéré (ICM) a été proposé comme une méthode itérative d'approximation de l'estimateur MAP. C'est un algorithme déterministe nécessitant une bonne valeur d'initialisation. Son principe est fondé sur la maximisation des probabilités conditionnelles locales en chaque site séquentiellement

En chaque site  $s$  on retient la classe qui maximise cette probabilité. L'algorithme ICM se résume comme suit:

- Initialiser une première carte "image"  $x^0$  d'une façon arbitraire
- A chaque itération  $n$  :
- Balayer l'ensemble des sites  $s \in S$  de  $x^{n-1}$  et en chaque site on calcule la probabilité conditionnelle, on pose :

$$x_s^n = \arg \max_{x_s \in \Omega} p(x_s | x_{v_s}^{n-1}) \quad (3.9)$$

- Refaire l'étape  $n$  jusqu'à réalisation d'un critère d'arrêt (par exemple lorsque le nombre de changements d'une étape à une autre devient suffisamment faible).

### Remarque

L'algorithme ICM converge vers le premier minimum local rencontré à partir des conditions initiales.

### 3.7.3 Estimateur du Mode des Marginales à posteriori (MMP)

Pour éviter la sévérité de la fonction de coût de l'estimateur MAP, une autre fonction de coût moins restrictive, est associée à l'estimateur MPM. Celle-ci est donnée comme suit:

$$L(\hat{x}_s, x_s) = \sum_{s \in S} 1 - \delta(\hat{x}_s, x_s) \quad (3.10)$$

Cette fonction consiste à pénaliser l'erreur commise en fonction du nombre de sites mal estimés (ou mal classés).

On montre que l'estimation Bayésienne  $\hat{x}$  est ici obtenue suivant:

$$\hat{x}_s = \arg \max_{\hat{x}_s} p(x_s | y) \quad (3.11)$$

Cette estimation ressemble à l'estimation du MAP, mais opérée de façon locale. Autrement dit, on passe de la probabilité conditionnelle globale d'une configuration, à la probabilité conditionnelle en un site.

Ainsi, la configuration optimale est atteinte lorsque toutes les lois marginales en chaque site sont maximisées. Cependant, le calcul direct et exact des probabilités a posteriori  $P(x_s | y)$  est

impossible, compte tenu du gigantisme de l'espace des configurations (3.3), mais le fait de pouvoir simuler des réalisations de  $X$  par des approximations de type Monte-Carlo décrites dans (3.2), permet leur estimation. En effet, on peut poser

$$\hat{p}(x_s = \omega | \mathbf{y}) = \frac{1_{[x_s^1 = \omega]} + \dots + 1_{[x_s^N = \omega]}}{N} \quad (3.12)$$

Finalement, pour la segmentation MPM, on procède de la manière suivante :

- Simuler  $N$  réalisations  $x^1, x^2, \dots, x^N$  de  $X$  selon la probabilité  $Y = y$  en utilisant l'échantillonneur de Gibbs
- Estimer à partir des réalisations  $x^1, x^2, \dots, x^N$  la loi de chaque  $X_s$  par les fréquences précédent (équation (3.12))
- Retenir la classe maximisant la loi ainsi obtenue. En d'autres termes choisir la classe dont le nombre d'apparitions dans les simulations est le plus grand.

### 3.8 Conclusion

Nous avons exposé dans ce chapitre la problématique générale de la segmentation par les modèles de Markov. Nous avons présenté les principaux algorithmes de segmentation.

La modélisation par champ de Markov rend compte des propriétés spatiales a priori des images observées, la modélisation par champ de Markov présente deux intérêts majeurs :

- (1) il s'agit d'un modèle facilement paramétrable ;
- (2) à cette souplesse s'ajoute l'avantage d'une formulation immédiate

En résumé, la modélisation markovienne constitue un cadre méthodologique adéquat pour introduire toutes sortes de contraintes pour améliorer le résultat de la classification non supervisée.

# *Résultats et interprétations*

## 4.1 Introduction

Le but de ce projet est de combiner l'utilisation des K-moyennes et des champs de Markov pour segmenter en régions distinctes une image satellitaire SPOT. La classification par k-moyennes nous permet d'obtenir des régions compactes dans l'espace RGB des couleurs, cependant les zones obtenues sont fragmentées au niveau de l'image. Cela est dû au fait qu'aucune information spatiale n'a été prise en compte lors de la classification par k-moyennes. Le formalisme des champs de Markov nous permet d'obtenir des classifications plus régulières en favorisant une régularité entre les pixels voisins. Cependant l'utilisation de ce modèle impose un certain nombre de choix : choix du système de voisinage pour les cliques, choix des potentiels associés aux cliques, choix de l'estimateur et de la méthode d'optimisation. Nous allons présenter et comparer les résultats obtenus en fonction des différents choix possibles.

## 4.2 Outils et méthodes

Nous avons choisit pour le teste de notre algorithme une scène d'une image SPOT 5 de 2007 couvrant la région de Bordj Senouci (Laghouat, Algérie). Cette image est issue du Projet (ISIS, CNES n°122)<sup>1</sup> est une image multispectrale de quatre bandes (Rouge, vert, Infrarouge et le moyen infra rouge) et d'une résolution 10 mètres.

Nous proposons l'application des deux méthodes de classification: Méthode des K-moyennes et la méthode des champs de Markov avec régularisation de la distance.

## 4.3 Application de la méthode des K-moyennes à la segmentation

L'image test est représentée par la figure 4.1. Une composition colorée a été faite pour une meilleure visibilité.






Figure 4.1 Extrait de l'image SPOT5 de la région de Bordj Senouci (Laghouat, Algérie)


<sup>1</sup> Projet de coopération entre la Wallonie (Belgique et l'université de Laghouat et de M'Sila (Algérie), 2007-2009)




(a) Deux classes



(b) Trois classes



(d) Six classes



(e) Huit classes

Figure 4.2 Résultats de la classification par la méthode de K- moyennes pour différents nombres de classes

### Problème de k-moyennes

Il n'y a pas de critère unique pour déterminer le meilleur nombre de classes ; Lorsque les classes ne sont pas bien séparées, les K-moyennes tendent à trouver uniquement des classes "sphériques", de même effectif et de même volume. Plusieurs initialisations peuvent conduire a plusieurs partitions très différentes dans leur composition (figure 4.2), mais très proches et quasi-optimales.

La méthode des K-moyennes est très attrayante pour obtenir rapidement une première classification. De plus, c'est une méthode simple et rapide. Cependant, pour le cas particulier des images satellitaires, la supposition a priori par ces méthodes que les limites entre les classes sont très bien définies peut poser problème, voir figure 4.3.




Figure 4.3 Différents résultats de la classification différents nombre de classes, (a) et (c) par K moyennes, (b) et (d) par champs de Markov

#### **4.4 Résultat de la régularisation des K-moyennes par champs de Markov(R-k-Moyennes par CMC)**

Dans cette partie plusieurs application de l'algorithme des champs de Markov à la même image de la figure 4.1, les résultats de l'algorithme avec et sans régularisation sont présentés. Nous avons choisi l'estimateur du mode conditionnel (ICM) pour notre travail.

— Cas de deux classes

Les résultats sont montrés sur la figure 4.4.

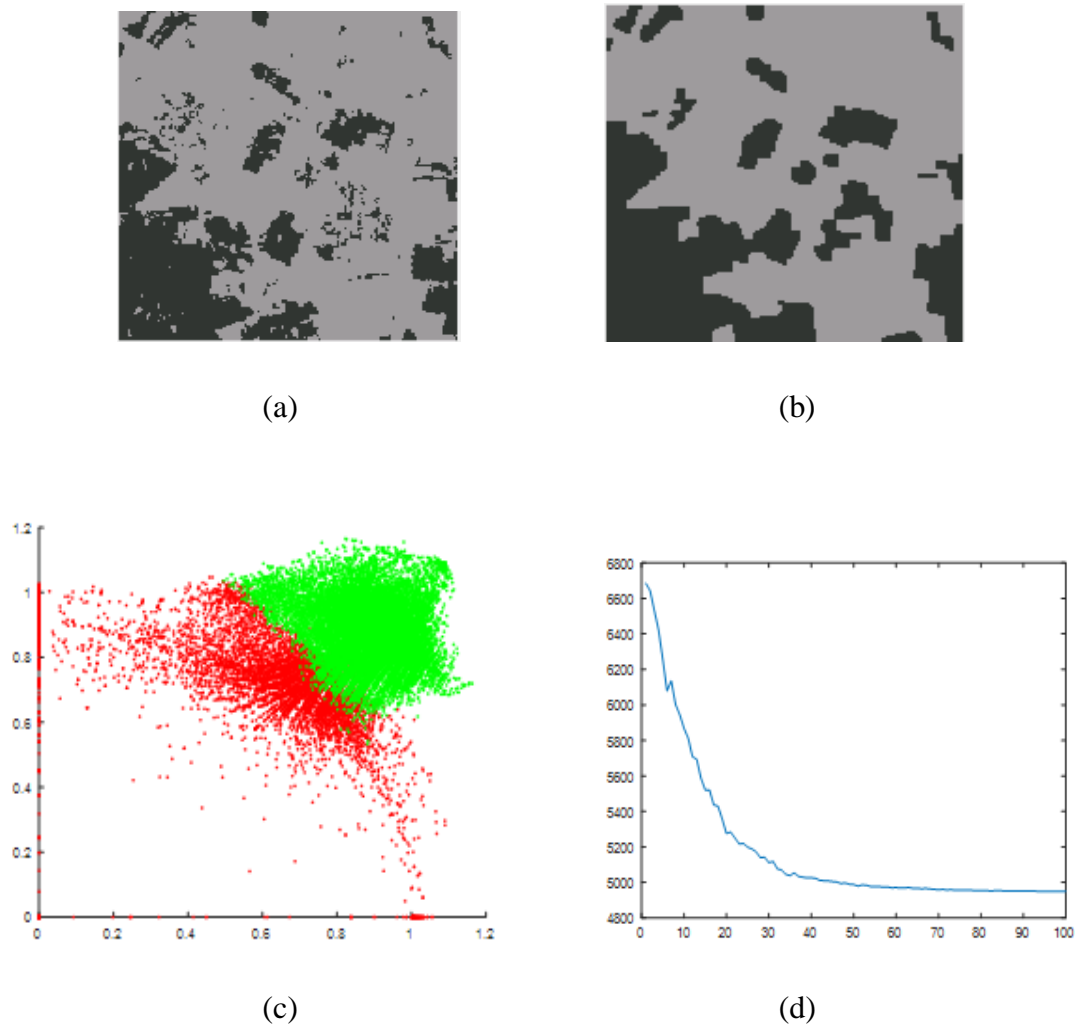


Figure 4.4 Résultats de l'application R-k-Moyennes par CMC; cas de deux classes, (a) sans régularisation; (b) avec régularisation, (c) carte des classes, (d) évaluation de la température.

### — Cas de quatre classes

Les résultats sont montrés sur la figure 4.5.

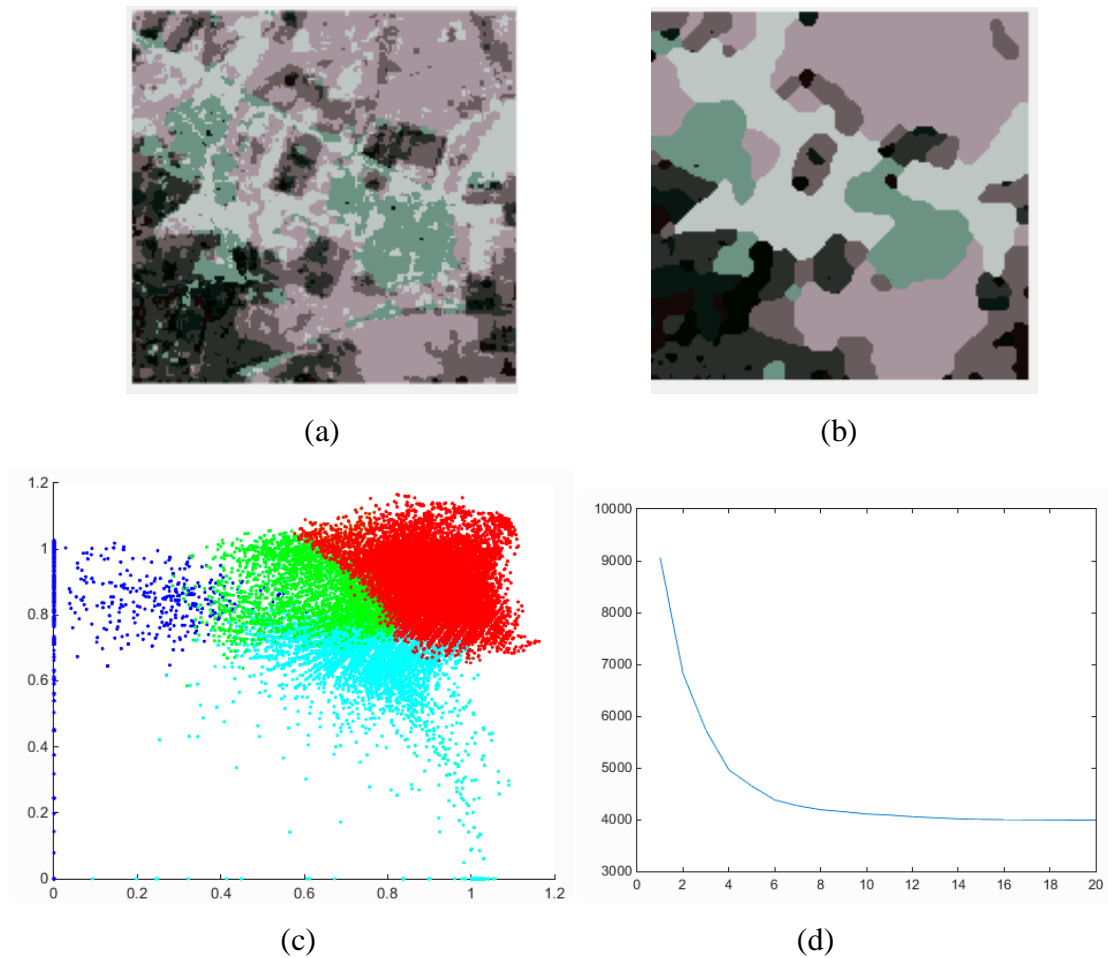


Figure 4.5 Résultats de l'application R-k-Moyennes par CMC :cas de quatre classes, (a) sans régularisation; (b) avec régularisation, (c) carte des classes, (d) évaluation de la température.

### Remarques

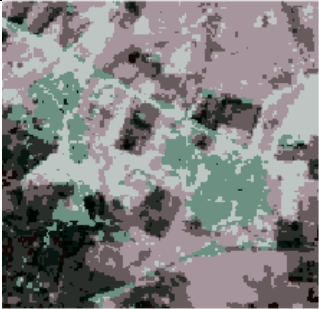
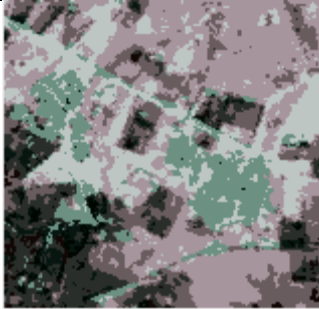
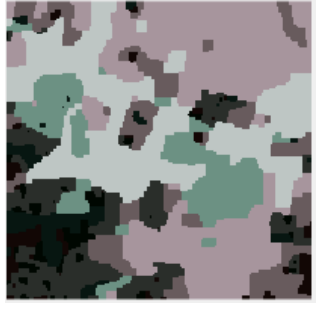
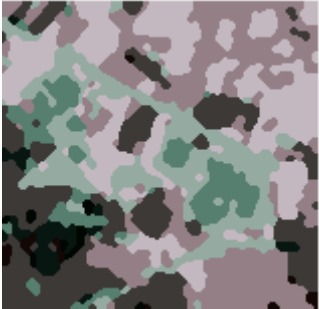
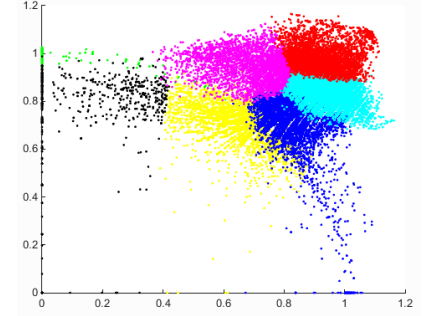
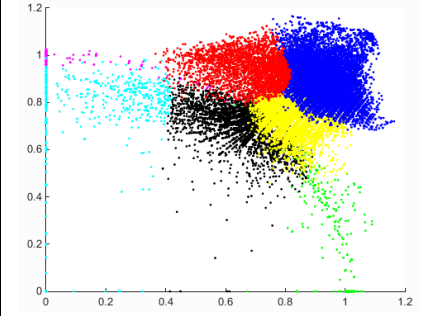
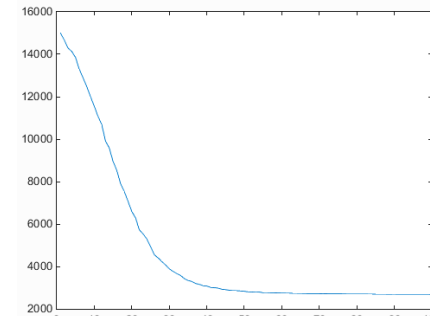
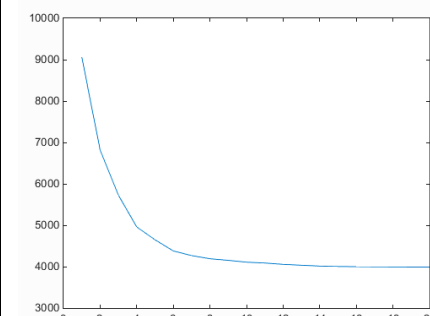
Dans les deux cas le nombre de cliques est choisi égale à 8;  $\beta=0.3$  et  $T_{init}=0.5$ ;

Le formalisme des champs de Markov nous permet d'obtenir des classifications plus régulières en favorisant une régularité entre les pixels voisins.

### 4.5 Rôle du choix des cliques dans la régularisation

Un autre choix à effectuer lors de l'utilisation des champs de Markov est celui des cliques. Faut-il utiliser un voisinage de 4 ou 8 pixels? Quel est le potentiel à attribuer à chaque configuration de cliques? Le tableau 4.1 illustre les résultats obtenus pour  $\beta = 0.3$ , le nombre de classes ( $nbc = 8$ ) et le temps initial ( $T_{init} = 0.5s$ ).

Tableau 4.1 Rôle des cliques

	4 connectivités	8 connectivités
Sans régularisation		
Avec régularisation		
Carte des classes		
Evaluation de l'énergie		

### Remarque

Le choix du voisinage et de ces potentiels est théoriquement lié à la physique de l'image que l'on souhaite segmenter. En effet ces potentiels représentent la connaissance que l'on a priori sur les probabilités de transitions dans la segmentation que l'on recherche. La recherche des paramètres optimaux pourrait se faire par apprentissage supervisé sur une banque d'images synthétiques. Cependant, du fait de leur nombre restreint il est tout à fait possible de les fixer de manière empirique en comparant différents choix.

## 4.6 Rôle du coefficient de régularisation

Lors de l'utilisation du modèle de champs de Markov nous devons fixer un certain nombre de coefficients du modèle. Un des coefficients à fixer est le coefficient  $\beta$  qui pondère la partie de l'énergie correspondant au modèle de Potts. Nous illustrons le rôle de ce coefficient en choisissant différentes valeurs :  $\beta$  pour plusieurs choix du nombre de classes (nbc) égale à 6, le nombre de cliques égale à 8 et  $T_{init}=0.5$ . Les résultats sont illustrés dans le tableau 4.2.

### Remarques

La comparaison des trois cas présentés permet d'illustrer la raison pour laquelle le coefficient  $\beta$  et parfois appelé facteur d'échelle. Lorsque le coefficient grandit les zones plus petites qu'une certaine échelle n'apparaissent plus dans la segmentation. Pour  $\beta$  faible ce sont les petites zones indésirables qui ont disparues.

Pour  $\beta=100$  ce sont les parties fines des zones bâties qui disparaissent, la régularisation est trop importante (voir figure 4.6).


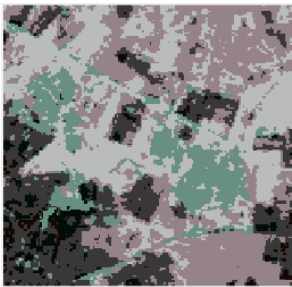
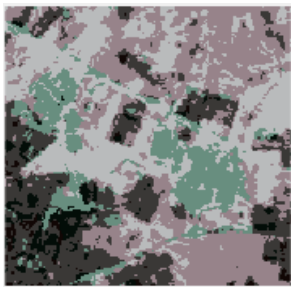
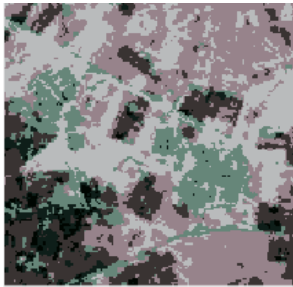
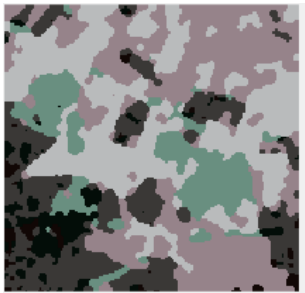

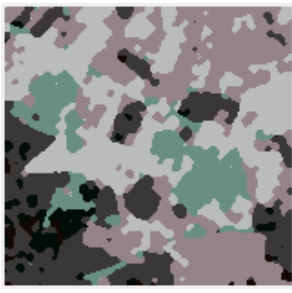
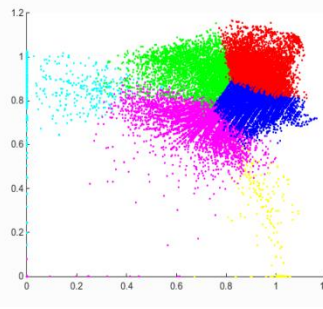
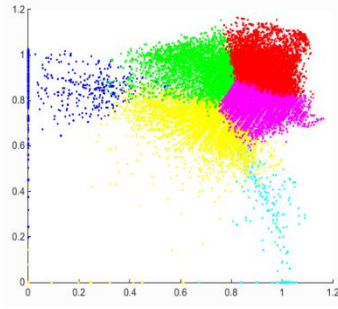
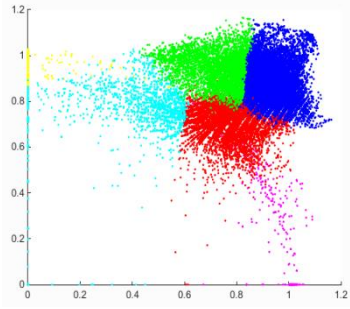
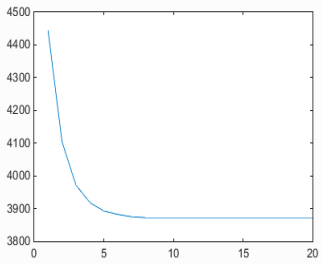
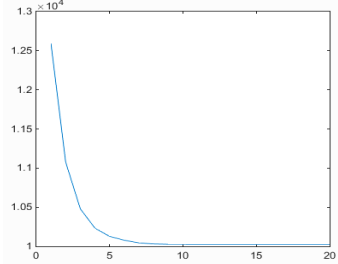
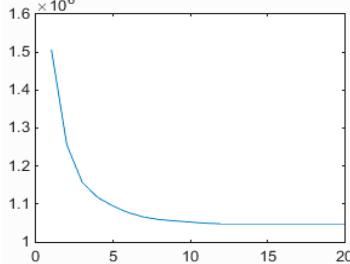


Figure 4.6 Résultat pour  $\beta=100$ , (a) sans régularisation, (b) avec régularisation

Tableau 4.2 Choix du coefficient de régularisation

	$\beta = 0.3$	$\beta = 0.8$	$\beta = 1$
Sans régularisation			
Avec régularisation			
Carte des classes			
Energie			

## 4.7 Conclusion

Nous pouvons conclure qu'un choix de voisinage plus grand donne une image plus régulière pour l'algorithme ICM. Cela s'explique par le fait qu'avec un plus grand voisinage l'algorithme ICM a moins de chance de tomber dans un minimum local. Par ailleurs le temps de convergence augmente avec le nombre de cliques.

# *Conclusion générale*

## Conclusion générale

La classification est un problème souvent étudié en télédétection, l'objet des méthodes de classification dont fait partie la méthode des K-means, cet algorithme est une version améliorée et randomisée de la méthode des nuées dynamiques. Il est actuellement l'un des plus utilisés et des plus efficaces en analyse des données. De fait, il permet de partitionner une population finie d'éléments en un nombre  $K$  (entier) de classes homogènes.

Il est utile de noter que l'algorithme K-means est très performant en termes de temps d'exécution, mais il souffre d'un défaut qui a son importance en segmentation d'images : elle introduit des discontinuités spatiales assez fortes aux frontières des classes.

Les MRF (Markov Random Field) se sont bien distingués des méthodes classiquement utilisées (méthodes non contextuelles) par la prise en compte des interactions locales entre chaque site (pixel) avec les pixels voisins pour définir les différentes régions de l'image. Ainsi, l'utilisation des champs de Markov permet de tenir compte de la propriété d'influence du voisinage d'un point sur ce dernier et d'insister donc sur la cohérence entre la classe d'un pixel et celle de ces voisins permettant de régulariser la classification d'images satellitaires.

Le but de ce travail est de combiner l'utilisation des K-means et des champs de Markov pour segmenter en régions distinctes une image satellitaire SPOT. La classification par K-means nous permet d'obtenir des régions compactes dans l'espace RGB des couleurs, cependant les zones obtenues sont fragmentées au niveau de l'image. Cela est dû au fait qu'aucune information spatiale n'a été prise en compte lors de la classification par K-means. Le formalisme des champs de Markov nous permet d'obtenir des classifications plus régulières en favorisant une régularité entre les pixels voisins. Cependant l'utilisation de ce modèle impose un certain nombre de choix : choix du système de voisinage pour les cliques, choix des potentiels associés aux cliques, choix de l'estimateur et de la méthode d'optimisation. Nous allons présenter et comparer les résultats obtenus en fonction des différents choix possibles.

Nous pouvons conclure qu'un choix de voisinage plus grand donne une image plus régulière pour l'algorithme ICM. Cela s'explique par le fait qu'avec un plus grand voisinage l'algorithme ICM a moins de chance de tomber dans un minimum local. Par ailleurs le temps de convergence augmente avec le nombre de cliques. Cet algorithme d'optimisation itératif ICM permet fil des itérations d'affiner la classification en accentuant les détails détectés par les contours de segmentation.

Cependant, on peut dire que les résultats obtenus à travers cette étude qu'ils soient pratiques ou théoriques permettent d'ouvrir la porte à d'autres études et perspectives dans le futur. Nous espérons que ce mémoire sera une référence aux personnes désirant développer des études dans le domaine de traitement d'image.

Les résultats trouvés sont satisfaisants, ce qui nous a permis de dire, que l'utilisation d'une méthode combinée entre plusieurs algorithmes de classification permet d'améliorer la qualité de la classification.

Comme perspectives à ce travail, nous pouvons proposer l'étude d'autres algorithmes d'optimisation tels que : Maximum a posteriori de la marginale.

## *Références bibliographiques*

## Références bibliographiques

- [1] [https://fr.wikiversity.org/wiki/Cat%C3%A9gorie:Chapitres\\_de\\_niveau\\_13](https://fr.wikiversity.org/wiki/Cat%C3%A9gorie:Chapitres_de_niveau_13), consulté le 20 juillet 2020.
- [2] Idbraim, I., (2009). Méthodes d'extraction de l'information spatiale et de classification en imagerie de télédétection : Applications a la cartographie thématique de la région d'Agadir (Maroc), *Thèse de doctorat en sciences de l'ingénieur* (spécialité : Informatique & Télécommunications, Université Paul Sabatier de Toulouse, 148p
- [3] Pony, O., Descombes, X., Zerubia, J. (2000). Classification d'images satellitaires hyper-spectrales en zone rurale et périurbaine. *Rapport de recherche*, RR-4008, INRIA. 2000, pp.64. ffinria-00072636f
- [4] Hannane, A.M, (2006). Conception d'un système hybride entre la Méta heuristique Electromagnétique et l'algorithme de colonie de fourmis pour la classification des images satellitaires. Mémoire de projet de fin d'étude. Université des sciences et de la technologie d'Oran Mohamed Boudiaf, Oran, Algérie
- [5] Bonn, F., & Rochon, G. (1992). Précis de télédétection volume 1: Principes et méthodes. Sainte- Foy: *Presse de l'université du Québec/AUPELF*, 485 p
- [6] Miramon-Ricquebourg, R. (1997).Cartographie des zones sensibles a l'érosion dans les rougiers de camarés ( sud-aveyron) application a une région test sur la commune de Montlaur, Mémoire d'études supérieures spécialisées (DESS), Aménagement Rural et Développement Local ,Montpellier2, France.
- [7] Pelletier, C. (2017). Cartographie de l'occupation des sols à partir de séries temporelles d'images satellitaires à hautes résolutions Identification et traitement des données mal étiquetées, *thèse de doctorat, Interfaces continentales, environnement*. Université Toulouse 3 Paul Sabatier (UT3 Paul Sabatier), France. {tel-01665121v2}
- [8] Coq, C. (2005).Cartographie détaillée de l'occupation et de l'utilisation du sol à partir de données satellitaires à très haute résolution en région sahélienne, Thèse de doctorat en sciences du milieu et de l'aménagement du territoire, UCL. AGRO/MILA - Département des,Louvain-la-Neuve : UCL, 98 p
- [9] Lavorini, D. (2010). Analyse rétrospective par télédétection de l'évolution du dépérissement des Sapins pectinés (abies alba) sur le Mont Ventoux, Institut National de la Recherche Mémoire d'ingénieur en mesure et aménagement du territoire, École Supérieure des Géomètres et Topographes (ESGT), Avignon, France
- [10] Benkouider, F., Abdellaoui, A., Hamami, L. (2018), New and Improved Built-Up Index Using SPOT Imagery: Application to an Arid Zone (Laghouat and M'Sila, Algeria), *Journal of the Indian Society of Remote Sensing* 47(2): .pp ,185-192.
- [11] Pekkarinen, A. (2002). Image segment-based spectral features in the estimation of timber

volume, *Remote Sensing of Environment*, 82(2-3), pp.349-35

- [12] Zitouni, A., Benkouider, F., Chouireb, F. (2019). Classification of Textured Images Based on New Information Fusion Methods, Source: IET Image Processing, Volume 13, Issue 9, p. 1540 - 1549, DOI: 10.1049/iet-ipr.2018.6256
- [13] Boukhari, I, Akli, R (2019). Essais de discrimination de l'espace urbain par segmentation des attributs texturaux, Mémoire de master en automatique (Option Automatique et informatique industrielle), Département d'électronique, Université Amar Telidji de Laghouat, Algérie
- [14] Lance, G., Williams, W. T. (1967). A general theory of classification sorting strategy, *Computer Journal* , Vol 9 n° 4, pp. 373-380. DOI:10.1093/comjnl/9.4.373.
- [15] Hajjar, C. (2014). Cartes auto-organisatrices pour la classification de données symboliques mixtes, de données de type intervalle et de données discrétisées. *Thèse de doctorat en traitement du signal*, Ecole doctorale Sciences et Technologies de l'Information, des Télécommunications et des Systèmes: 2014SUPL0066ff. fftel-01142849f
- [16] Tonye, E. et Akono, L. (2000). Traitement des images de télédétection par l'exemple Ed. GORDON AND BREACH, Collection: univers de la Télédétection
- [17] Jahne, B. (2015). Digital Image Processing, Springer-Verlag Berlin Heidelberg, 368 p, DOI:10.1007/3-540-27563-0
- [18] Notions fondamentales de télédétection, Cours tutorial du centre canadien de télédétection, 262 p, <https://www.rncan.gc.ca/cartes-outils-publications/imagerie-satellitaire-photos-aer/tutoriel-notions-fondamentales-teledetection/9310>. Consulté le 20/07/2020.
- [19] Loyd. S. P. (1982). Least squares quantization in PCM. *IEEE Transactions on Information Theory* 28 (2):129–137. doi:10.1109/TIT.1982.1056489.
- [20] AKROUR, N. et CHABI, L., Mémoire de fin d'études, « Une plateforme évolutive pour le développement d'approches biomimétiques en segmentation d'images », Ecole nationale Supérieure d'Informatique (ESI) Oued-Smar, Alger, Promotion : 2008/2009
- [21] <http://www.tsi.enst.fr/tsi/enseignement/ressources/mti/markovfield/node4.html>, Consulter le 22.08.2020 à 02 :10
- [22] Luzárraga, E. et Pacheco, M. (2013). "Segmentation automatique d'images IRM anténatales", Thèse de Fin d'études, Télécom PARIS-TECH
- [23] Lecoeur, J., Barillot, C. (2007). Segmentation d'images cérébrales : État de l'art, Rapport de recherche, Thème BIO, Institut National de Recherche en Informatique et Automatique, inria-00175188, version 1 - 27
- [24] Ising, E. (1925). Beitrag zur Theorie des Ferromagnetismus, *Zeitschrift fur Physik*, 31 pp. 253–258.
- [25] Abend, K., Harley, T. J et Kanal, L. N. (1965). Classification of binary random pattern, *IEEE Transactions on Information Theory*, 11, pp. 538–544.
- [26] Geman, S., Geman, D. (1984). Stochastic Relaxation, Gibbs Distribution, and the Bayesian Restoration of Images, *IEEE Transactions on Pattern Analysis and Machine Intelligence*,

- PAMI-6, pp. 721–741.
- [27] Kharoubi, M.A.(2013), Segmentation d’image médicale par champs de Markov, Mémoire de magistère en électronique(option signaux et applications), département de génie électrique, faculté de sciences et technologie, université Abdelhamid Ibn Badis de Mostaganem.
- [28] Li, S. Z. (1995).“Markov Random Field Modelling in Computer Vision”, Springer
- [29] Broniatowski ,M, Celeux,G et Diebolt, J.( 1983).“Reconnaissance de mélanges de densités par un algorithme d'apprentissage probabilistes”, In Data Analysis and Informatics 3, E. Diday (Ed.), North Holland, Amsterdam, pp. 359-373
- [30] Pieczynski, W.( 1992). “Statistical image segmentation”, Machine Graphics and Vision, Vol.1, No. 1/2, pp. 261-268.