

Segmentation des Images Satellite :
Application à la Classification de la
Couverture et de l'Utilisation du Sol

Saleh EL JOUMANI

17/07/2023

Dédicaces

DEDICACES

je remercie mes parents, mes frères et mes amis qui, dans l'ombre, m'ont toujours encouragé. Leur soutien s'est avéré déterminant pour mener ce travail à terme. Merci encore !

Remerciements

REMERCIEMENTS

Cette thèse a été réalisée au sein du laboratoire Conception et Systèmes (Electronique, Signaux et Informatique)(LCS) à la Faculté des Sciences de l'Université Mohammed V de Rabat, sous la direction de Monsieur Lhoussaine MASMOUDI. Professeur d'Enseignement Supérieur.

D'après Abou Houreira (qu'Allah l'agrée), le Prophète (que la prière d'Allah et Son salut soient sur lui) a dit : « Celui qui ne remercie pas les gens n'a pas remercié Allah ».

Tout d'abord, je tiens à remercier Monsieur Lhoussaine MASMOUDI, Professeur d'Enseignement Supérieur à la faculté des sciences de Rabat, mon directeur de thèse, qui m'a fait exposer la vision par ordinateur, depuis mon projet de fin d'études du cycle master, et m'a initié à l'art de l'écriture d'articles. Sans son soutien, à la fois scientifique, moral et matériel, ce travail n'aurait pas été possible. Je lui exprime ici, ma profonde gratitude pour la qualité de son encadrement, sa patience, ses compétences scientifiques et humaines que j'ai beaucoup appréciés tout au long des travaux de ma thèse.

Je tiens à exprimer ma gratitude sincère à Monsieur Ilias KACIMI, Professeur d'Enseignement Supérieur à la Faculté des Sciences de Rabat de m'avoir fait l'honneur de présider le Jury de cette thèse.

Je présente mes plus sincères remerciements à Monsieur Aziz AMARI, Professeur d'Enseignement Supérieur à la Faculté des Sciences, Université Mohammed V de Rabat pour avoir soumis ses précieux jugements sur la qualité et le contenu de ce travail.

J'ai le grand plaisir d'exprimer mes plus chaleureux remerciements à Madame Mounia ZAIM, Professeure habilitée à l'Ecole Supérieure de Technologie de Salé, Université Mohammed V de Rabat pour avoir accepté d'évaluer ce

REMERCIEMENTS

travail en tant que rapporteur et examinateur.

J'ai le grand plaisir d'exprimer mes plus chaleureux remerciements à Monsieur Lahcen KOUTTI, Professeur d'Enseignement Supérieur à la Faculté des Sciences, de l'Université IBN ZOHR d'Agadir pour avoir accepté d'évaluer ce travail en tant que rapporteur et examinateur.

Je tiens également, à remercier Monsieur Mohamed EL ANSARI, Professeur Professeur d'Enseignement Supérieur à la Faculté des Sciences, de l'Université Moulay Ismail de Meknès qui a accepté d'être mon examinateur de ma soutenance.

Veuillez accepter ma sincère gratitude à tous ceux qui ont contribué directement ou indirectement à la réalisation de cette étude.

Résumé

Cette étude fait partie du développement continu des techniques de segmentation d'images satellitaires à très haute résolution spatiale.

L'objectif de cette étude est d'améliorer la technique de segmentation hiérarchique des histogrammes 2D utilisée pour les images satellitaires. L'approche de base que nous avons améliorée utilisait généralement des techniques de segmentation qui ne prenaient pas en compte les corrélations spectrales et spatiales existantes entre les pixels de l'image. Trois techniques de segmentation ont été développées dans le cadre du même concept d'analyse hiérarchique des histogrammes 2D. La première est fondée sur la fonction d'optimisation multiobjective appliquée aux images panchromatiques. La deuxième est basée sur la physique quantique par la résolution de la fonction d'onde et l'entropie de *Tsallis* appliquée aux images multispectrales. La troisième est basée sur la physique quantique et l'entropie : cas de l'entropie de *Havrda-Charvat*. Nous avons appliqué ces approches à des images synthétiques texturées en niveau de gris et en couleur. Les méthodes développées ont produit des cartes de segmentation compactes et homogènes. En fait, pour évaluer nos méthodes de segmentation d'images multispectrales du satellite QuickBird, nous avons exploité les critères suivants : Pour la première méthode (la segmentation d'optimisation multiobjective) nous nous sommes basés sur les critères de *Levine* et *Nazif* Pour la deuxième et la troisième méthode, nous avons utilisé le coefficient d'évaluation de *Borsotti*.

En ce qui concerne les résultats de segmentation des images multispectrales obtenus par ces techniques nous sommes extrêmement satisfaits, la couverture et l'utilisation du sol ont été correctement détectées et identifiées, et les techniques ont reproduit correctement les régions.

Mots-clés :

Images multispectrales , histogramme 2D, segmentation et classification, fonction d'onde, optimisation multiobjective et entropie.

Abstract

This study is part of the ongoing development of satellite image segmentation techniques at very high spatial resolution.

The objective of this study is to improve the hierarchical segmentation technique of 2D histograms used for satellite images. The basic approach that we improved typically used segmentation techniques that did not take into account existing spectral and spatial correlations between image pixels. Three segmentation techniques were developed within the same concept of hierarchical analysis of 2D histograms. The first is based on the multiobjective optimization function applied to panchromatic images. The second is based on quantum physics by the resolution of the wave function and the Tsallis entropy applied to multispectral images. The third is the same as the second but with change in entropy, we will use the Havrda-Charvat entropy. We applied these approaches to grayscale and color textured synthetic images. The methods developed produced compact and homogeneous segmentation maps. In fact, to evaluate our multispectral image segmentation methods from the QuickBird satellite, we used the following criteria : For the first method (multiobjective optimization segmentation) we based ourselves on the criteria of Levine and Nazif For the second and third methods, we used the Borsotti evaluation coefficient.

Regarding the multispectral image segmentation results obtained by these techniques, we are extremely satisfied, the land cover and land use were correctly detected and identified, and the techniques reproduced the regions correctly.

Keywords :

Multispectral images , 2D histogram, segmentation and classification, wave function, multiobjective optimization and entropy.

Liste des Tableaux

Liste des tableaux

2.1	Résolutions spatial et spectral du Satellite IKONOS	25
2.2	Résolutions spatial et spectral du Satellite QuickBird	26
2.3	Résolutions spatial et spectral du Satellite QuickBird	27
4.1	Les valeurs des critères d'évaluation de Levine et Nazif des deux fonctions d'optimisation multiobjectives (MOBJ1 et MOBJ2).	81
4.2	les valeurs d'évaluation des différentes méthodes pour les images synthétiques.	83
4.3	Caractéristiques des bandes multispectrales de l'image QuickBird MS.	86
4.4	Valeurs d'évaluation du critère de Levine et Nazif pour diverses méthodes (Images panchromatiques).	88
4.5	Valeurs de la fonction d'évaluation Q de Borsotti pour l'image synthétique par la méthode proposée	93
4.6	Valeurs de la fonction d'évaluation Q de Borsotti pour l'image synthétique par la méthode précédente [117]	94
4.7	Valeurs de la fonction d'évaluation Q de Borsotti pour l'image QuickBird . . .	98
4.8	Valeurs de la fonction d'évaluation Q pour l'image synthétique par différentes valeurs du paramètre q	101
4.9	Différentes valeurs de la fonction d'évaluation Q par différentes valeurs du paramètre q pour l'image QuickBird (a)	102
4.10	Différentes valeurs de la fonction d'évaluation Q par différentes valeurs du paramètre q pour l'image QuickBird (b)	103
4.11	Valeurs de la fonction d'évaluation Q de Borsotti pour l'image synthétique par la méthode proposée	106
4.12	Valeurs de la fonction d'évaluation Q de Borsotti pour l'image QuickBird . . .	111

LISTE DES TABLEAUX

4.13 Valeurs de la fonction d'évaluation Q pour l'image synthétique par différentes valeurs du paramètre α	118
4.14 Différentes valeurs de la fonction d'évaluation Q par différentes valeurs du paramètre α pour l'image QuickBird (a)	119
4.15 Différentes valeurs de la fonction d'évaluation Q par différentes valeurs du paramètre α pour l'image QuickBird (b)	120

Liste des Figures

Table des figures

1.1	Principe général de la télédétection.	8
1.2	Les sept étapes du processus de télédétection selon [15]	9
1.3	Satellite en orbite géostationnaire	13
1.4	Satellite en orbite héliosynchrone	13
1.5	Satellite en Orbite ascendante et orbite descendante	14
3.1	Principe de la segmentation par croissance des régions	32
3.2	Principe de la segmentation par division des régions (Structure quaternaire) .	33
3.3	Les 8 et 4 voisins de $P(x,y)$	33
3.4	Hierarchie de la méthode de segmentation par fusion	34
3.5	Principe de la segmentation par division/fusion	35
3.6	Histogramme de répartition à trois modes	35
3.7	Structure d'un neurone	36
3.8	Un exemple de décomposition hiérarchique. Les feuilles encadrées (partie b) correspondent à des pics significatifs tels qu'obtenus à l'issue de la décomposition itérative (traits pleins en partie a), tandis que les feuilles marquées $< S$ (partie b) correspondent à des pics non significatifs (en pointillés en partie a)	38
3.9	Le processus classique de détection de contours	40
3.10	Contour et ses dérivées	41
3.11	Evolution du contour actif $\Gamma(\tau)$ avec la vitesse v vers l'objet d'intérêt	45
3.12	Coopération séquentielle	47
3.13	Coopération des résultats	47
3.14	Coopération mutuelle	48

TABLE DES FIGURES

3.15 Exemple de seuillage d'une image à deux classes à l'aide de l'histogramme . .	49
4.1 Modèle de la Particule.	64
4.2 Evaluation supervisée avec vérité de terrain	68
4.3 Evaluation supervisée avec vérité de terrain experte	69
4.4 Segmentation d'images par les deux fonctions d'optimisation multiobjectives.	82
4.5 Résultats de la segmentation des images synthétiques.	84
4.6 zone d'étude – image panchromatique QuickBird – région d'intérêt pour l'image panchromatique (zones urbaines, forêt et rivière)	85
4.7 Résultats de la segmentation des images panchromatiques.	87
4.8 L'image synthétique sélectionnée	93
4.9 Résultat de segmentation pour image synthétique	94
4.10 QuickBird RGB Image - Zone d'étude sélectionnée.	96
4.11 Résultat de segmentation pour l'image QuickBird	97
4.12 l'image synthétique sélectionnée	106
4.13 Résultats de segmentation pour image synthétique utilisant la distance de Mahalanobis	107
4.14 Résultats de segmentation pour image synthétique utilisant la distance Eu- clidienne	108
4.15 QuickBird RGB Image - Zone d'étude sélectionnée.	110
4.16 Résultats de segmentation pour l'image Quikbird (a) en utilisant la distance euclidienne	112
4.17 Résultats de segmentation pour l'image Quikbird (a) en utilisant la distance de Mahalanobis	113
4.18 Résultats de segmentation pour l'image Quikbird (b) en utilisant la distance euclidienne	114
4.19 Résultats de segmentation pour l'image Quikbird (b) en utilisant la distance de Mahalanobis	115

Abréviations

ABREVIATIONS

LCS	laboratoire Conception et Systèmes (Electronique, Signaux et Informatique)
SAR	Images de radar à ouverture synthétique
LIDAR	Images de détection de lumière et de distance
PAN	panchromatique
MS	Multi-Spectral
SS	Super-Spectral
HS	Hyper-Spectral Teinte, Saturation et Luminosité)
2D	Deux Dimensions
<i>RGB</i>	Red Green Blue (Rouge, Vert et Bleu)
<i>Min</i>	Minimum
<i>Max</i>	Maximum
$MVar(I)$	Le critère de la variance intra-classe
MOBJ1	La fonction multiobjective appliquée aux images à deux seuils (images médicales) par Nakib
MOBJ2	La fonction objective modifiée par l'introduction de l'information sur l'entropie
LEV1	Le critère d'uniformité intra région
LEV2	Le critère de la disparité totale entre les régions
LEV3	Le critère des disparités intra et inter régions
I	Une image
R_i	Région i
H	Histogramme
$V(x, y)$	L'énergie potentielle
$E\Psi(x, y)$	La fonction d'onde
$\hbar$	La constante de Planck réduite : $\hbar^2 = \frac{h}{2\pi}$
m	La masse de la particule
E	La valeur propre de l'énergie
$ \psi ^2$	La densité de probabilité
N_C	Le nombre de colonnes
N_L	Le nombre de lignes

ABREVIATIONS

r, g et b	Les valeurs de pixel respectivement dans le plan R, G et B de l'image
p_{max} et p_{min}	Respectivement la valeur minimale et la valeur maximale de P
$Q(I)$	Fonction d'évaluation proposée par BORSOTI et al
N	La taille de l'image
R	Le nombre de régions de l'image segmentée
N_i	La surface de la $i^{ème}$ région
$R(N_i)$	Le nombre de régions ayant une surface égale à N_i
e_i	L'erreur moyenne des couleurs de la $i^{ème}$ région
E_{TP}	L'entropie totale
K	Kelvin
T	La Température
s_i	le seuil i
m_i	la valeur moyenne de l'intensité lumineuse dans la classe $n^oi : C_i$
t_i	La taille partielle correspondant à la classe C_i
v_i	La variance partielle correspondant à la classe C_i
W	La variance intra-classe totale
B	La maximisation de la variance inter-classe développée par OTSU
$E_{TP}(C_i)$	L'entropie partielle de la classe n^oi
D_i	L'ensemble des niveaux de gris j associés à la classe C_i
p_j	La probabilité à postériori du niveau de gris j
F	La fraction surfacique
$d(k)$	L'intégrale normalisée de l'histogramme entre les bornes 1 et k
g_i	La répartition spatiale des niveaux de gris dans l'image
p_n	Désigne niveau de gris
p_i	Désigne les pics

ABREVIATIONS

p_{min} et p_{max}	Respectivement les valeurs minimale et maximale de p
NR	Le nombre de régions de l'image I
α	Calculée par $\frac{1}{10000XM}\sqrt{NR}$
M	La taille de l'image I
β_j	Désigne le nombre de pixels dans la région J .
γ_j	Le nombre de régions dont le cardinal est égal à N_j .
j	Le nombre de régions,
P_j	La probabilité de la classe j ,
m_j	L'intensité des pixels de la classe j
m_G	La moyenne globale,
P_i	La fonction de densité de probabilité des différents pixels de l'image
$h(i)$	Le nombre d'occurrences du niveau de gris du pixel $i \in [0, L - 1]$
L	Le nombre total de niveaux de gris
$e(T_i)$	La fonction de probabilité d'erreur
$E(T)$	La probabilité globale à minimiser
T	Le vecteur de seuils : $0 < T1 < T2 < \dots < Td - 1 < 255$
E_{TP_A}	L'entropie de la classe A
E_{TP_B}	L'entropie de la classe B
E_{TP_T}	L'entropie totale
w_1, w_2, w_3	Les paramètres de pondération
I_R	Correspond au résultat de segmentation de l'image dans un ensemble de régions $R = R_1, \dots, R_{NR}$ ayant NR régions
$Card(I)$	Correspond au nombre de pixels de l'image
$g_I(s)$	Correspond à l'intensité de niveau de gris du pixel s de l'image I
R_k	Les pixels de la région
W_{R_k}	C'est le poids associé à R_k
$\bar{g}_k$	C'est la moyenne des niveaux de gris de R_k

ABREVIATIONS

$\bar{g}_I(R_k)$	C'est le vecteur caractéristique calculé sur les valeurs de pixels de la région R_k
$p_{R_k \setminus R_j}$	Correspond à la longueur du périmètre de la région R_k commune au périmètre de la région R_j
$C_{N_R}^2$	C'est le nombre de combinaisons de 2 régions parmi N_R

Table des Matières

Table des matières

Dédicaces	i
Remerciements	iii
Résumé	vi
Abstract	viii
Liste des Figures	xii
Abréviations	xv
Table des Matières	xx
Introduction Général	1
1 Télédétection et analyse des images	5
1.1 Introduction :	6
1.2 Télédétection :	7
1.3 Acquisition des données de télédétection :	9
1.3.1 Plateformes d'acquisition :	11
1.3.1.1 Plateformes terrestres :	11
1.3.1.2 Plateformes aériennes :	11
1.3.1.3 Plateformes spatiales :	11
1.3.2 Caractéristiques des satellites :	12
1.3.2.1 Orbite :	12
1.3.2.1.1 Orbite géostationnaire :	12

TABLE DES MATIÈRES

1.3.2.1.2	Orbite héliosynchrone :	12
1.3.2.1.3	Orbite ascendante et orbite descendante :	13
1.3.2.2	Couloir-couver ou fauchée :	14
1.3.2.3	Points nadir :	14
1.4	Conclusion :	15
2	Imagerie Satellitaire	16
2.1	Introduction :	17
2.1.1	Types des images de télédétection :	18
2.1.1.1	Classification spectrale :	18
2.1.1.1.1	Images de radar à ouverture synthétique (SAR) : . .	18
2.1.1.1.2	Images optiques :	19
2.1.1.1.2.1	Images panchromatiques	19
2.1.1.1.2.2	Images multi-spectrales :	20
2.1.1.1.2.3	Images super-spectral et hyper-spectral : . .	20
2.1.1.1.3	Images de détection de lumière et de distance (lidar) : .	21
2.1.1.2	Classification spatiale :	22
2.1.1.2.1	Faible résolution :	22
2.1.1.2.2	Résolution moyenne :	23
2.1.1.2.3	Haute et très haute résolution	23
2.1.2	Caractéristiques des satellites de haute résolution spatiales :	24
2.1.2.1	Satellite IKONOS :	25
2.1.2.2	Satellite QuickBird :	25
2.1.2.3	Satellite GeoEye-1 :	26
2.2	Conclusion :	27
3	Segmentation des images numériques	28
3.1	Introduction :	29
3.2	Techniques de segmentations d'images :	31
3.2.1	Segmentation par l'approche « régions » :	31
3.2.1.1	Croissance des régions :	31
3.2.1.2	Division des régions :	32
3.2.1.3	Fusion de région (Bottom-Up) :	33
3.2.1.4	Division/fusion « Splitting and Merging » :	34

TABLE DES MATIÈRES

3.2.1.5	Classification :	35
3.2.1.5.1	Classification supervisée :	36
3.2.1.5.1.1	Réseaux de neurones artificiels :	36
3.2.1.5.2	Classification non supervisée :	36
3.2.1.5.2.1	Classification par analyse hiérarchique d'his- togramme 2D :	36
3.2.2	Segmentation par l'approche «contours »	39
3.2.2.1	Processus « classique » de détection de contours :	40
3.2.2.1.1	Méthodes dérivatives :	40
3.2.2.1.2	Méthodes analytiques :	43
3.2.2.1.3	Méthodes déformables	44
3.2.2.1.4	Limites de la segmentation par contour :	46
3.2.3	Segmentation par l'approche «coopérative »	46
3.3	Seuillage	47
3.3.1	Seuillage global	49
3.3.1.1	Méthodes paramétriques :	50
3.3.1.2	Méthodes non paramétriques :	51
3.3.1.2.1	Methode d'Otsu :	51
3.3.1.2.2	Seuillage entropique :	53
3.3.1.2.3	Méthode K-means :	54
3.3.2	Seuillage local	56
3.4	Conclusion :	57
4	Approches développées	58
4.1	Introduction :	59
4.2	Approche multicritère :	59
4.2.1	Critère de la variance intra-classe	60
4.2.2	Critère de la probabilité globale	61
4.2.3	Critère de l'entropie	62
4.2.4	Fonction multiobjective :	62
4.3	Approche quantique :	63
4.3.1	Modèle pour la Particule :	63
4.4	Critères d'évaluation :	65

TABLE DES MATIÈRES

4.4.1	Différents types d'erreurs de segmentation :	66
4.4.2	Classification des Algorithmes d'évaluation :	66
4.5	Critères d'évaluation supervisée :	67
4.5.1	Évaluation avec une vérité terrain synthétique :	67
4.5.2	Évaluation avec une vérité terrain réalisée par un expert :	67
4.5.3	Evaluation de la segmentation en contours :	69
4.5.3.1	Critères de Pratt :	69
4.5.3.2	Critères de Fram et Deutsch :	70
4.5.3.3	Critères de Peli et Malah :	71
4.5.4	Evaluation de segmentation en régions :	72
4.5.4.1	Critère de Vinet :	72
4.5.4.2	Critère de Yasnoff :	72
4.5.4.3	Critère de Martin :	73
4.6	Critères d'évaluation non supervisée :	74
4.6.1	Évaluation analytique :	75
4.6.2	Évaluation de critères de qualité :	75
4.6.2.1	Évaluation de la segmentation en contours :	75
4.6.2.1.1	Critère de Kitchen et Rosenfeld :	76
4.6.2.1.2	Critère de Leving et Nazif :	76
4.6.2.1.3	Critère de Han et Kim :	77
4.6.2.2	Évaluation de la segmentation en région :	78
4.6.2.2.1	Critère de Borsotti :	78
4.6.2.2.2	Critères de Levine et Nazif :	79
4.6.2.2.3	Critère de Rosenberger :	80
4.7	Applications :	80
4.7.1	Méthode de segmentation basée sur l'optimisation multiobjective pour les images satellites à très haute résolution spatiale :	80
4.7.1.1	Evaluation de la fonction d'optimisation multiobjective développée :	81
4.7.1.2	Base de données :	82
4.7.1.2.1	Images synthétiques :	82
4.7.1.2.2	Images satellites"Image Quickbird" :	85
4.7.1.3	Résultats expérimentaux et discussion :	89

TABLE DES MATIÈRES

4.7.2	Classification des images satellites basée sur l'approche quantique et l'entropie de Tsallis :	90
4.7.2.1	Méthode proposée :	91
4.7.2.2	Méthode de classification :	92
4.7.2.3	Base de données :	92
4.7.2.3.1	Images synthétiques :	93
4.7.2.3.2	Images satellites "Image Quickbird" :	95
4.7.2.4	Résultats expérimentaux et discussion :	99
4.7.2.5	Influence du paramètre q dans la segmentation d'images : . .	100
4.7.3	Segmentation d'images satellite basée sur l'approche quantique et l'entropie Havrda-Charvat :	104
4.7.3.1	Méthode proposée :	104
4.7.3.2	Méthode de classification :	105
4.7.3.3	Base de données :	106
4.7.3.3.1	Image synthétique :	106
4.7.3.3.2	Images satellites "Image Quickbird" :	108
4.7.3.4	Résultats expérimentaux et discussion :	115
4.7.3.5	Influence du paramètre α dans la segmentation d'image : . .	116
4.8	Conclusion :	121
	Conclusion générale et perspectives	123
	Liste des travaux de recherche	126
	Bibliographie	129

Introduction

La nouvelle époque de la communication s'annonce, le développement de la science et des nouvelles technologies, ainsi que les progrès de l'électronique et de l'informatique, font de l'image un support de base de l'information.

Les domaines tels que la télédétection, la médecine, la biologie, ... se voient dans l'obligation de se conformer aux champs dont l'image est devenue la source la plus fiable de l'information.

De plus, de nombreuses images multispectrales avec une résolution spectrale et spatiale très élevée sont produites à chaque instant grâce aux progrès technologiques des capteurs et de la capacité des mémoires de stockage. Qu'est-ce qui fait des images, l'élément le plus couramment utilisé et dominant dans de nombreuses disciplines.

En fait, le modèle visuel le plus riche de l'espace géographique est l'image de télédétection aérienne et satellitaire. Pour le moment, elle est la source intarissable des informations les plus précises sur la couverture et l'utilisation du sol, ainsi que sur les phénomènes à la surface de la planète. Grâce à l'image satellite de très haute résolution spatiale, de nombreuses perspectives et applications s'ouvrent à la recherche dans les domaines de l'environnement tels que l'hydrologie, l'agriculture, le développement urbain, la détection des feux de forêts, le changement climatique, etc. La détection d'objets en imagerie reste une opération marquante dans l'analyse et le traitement des données. De façon efficace, la segmentation de l'imagerie satellite participe à résoudre le problème de détection des différents types d'objets.

Par conséquent, la segmentation est une étape cruciale du traitement d'images car

INTRODUCTION

elle affecte la qualité de l'interprétation et la prise de décision effectuée sur l'image. En fait, il s'agit d'extraire une information structurée de haut niveau pour la reconnaissance et l'indexation des images. La qualité de l'interprétation dépend fortement de celle de la segmentation.

Cependant, il n'existe pas de techniques de segmentation universelles et le choix d'une technique est difficile car il dépend de divers facteurs, tels que la nature de l'image (éclairage, contours, texture,...), des opérations en aval de la segmentation (reconnaissance des formes, compression, mesure, interprétation), des primitives à extraire (textures, régions, droites,...) et des contraintes d'exploitation (temps réel, mémoire,...).

Malgré la variété des méthodes utilisées, les résultats de la segmentation sont modestes, et varient en fonction de la technique choisie. Par conséquent, des types d'erreurs de segmentation peuvent survenir comme : la sur-segmentation, qui crée des zones qui ne correspondent à aucun objet de la scène, ou la sous-segmentation, qui ne distingue pas l'ensemble des objets de la scène. En général, une seule méthode dans le domaine de la segmentation automatique ne permet pas de segmenter efficacement la diversité des régions.

En raison des capteurs plus performants, les données décrivent de mieux en mieux la scène, en outre, la taille est de plus en plus primordiale (imagerie multi et hyper spectrale). En conséquence, les traitements deviennent de plus en plus difficiles et plus difficiles à réaliser, mais la nature multispectrale des images empêche l'utilisation directe des techniques de traitement utilisées en niveaux de gris. Par suite, de nouvelles techniques de segmentation doivent être créées pour identifier les zones d'intérêt dans les images multispectrales.

Ces dernières années, un certain nombre de solutions à la segmentation ont été proposées. Certains sont basées sur les caractéristiques spatiales de l'image et d'autres utilisent l'information spectrale de l'image.

Toutefois, ces méthodes emploient généralement des stratégies de segmentation qui ignorent les corrélations spectrales et spatiales qui peuvent exister entre les pixels de l'image. De laquelle, il est nécessaire de créer de nouvelles techniques de segmentation qui tiennent

INTRODUCTION

compte de l'information vectorielle et spatiale présente dans les images multispectrales.

Notre intérêt dans cette thèse est la segmentation des images multispectrales, en particulier les images satellite de très haute résolution spatiale - les images d'étude sont des images Quickbird MS. Par conséquent, nous présenterons trois méthodes différentes pour la segmentation d'images multispectrales. La première est basée sur la fonction d'optimisation multiobjective, la deuxième est basée sur la physique quantique par la résolution de la fonction d'onde et l'entropie de Tsallis, et la troisième est la même que la deuxième mais avec un changement d'entropie, nous avons utilisé l'entropie de Havrda-Charvat. Ces trois techniques visent à améliorer la segmentation des images satellites multispectrales.

Cette thèse est structurée en quatre chapitres comme suit :

Dans le premier chapitre, nous expliquerons tout d'abord, le processus de la télédétection et l'acquisition de ses données.

Puis, nous présentons les différents types des images satellitaires et leurs caractéristiques, dans le deuxième chapitre, les caractéristiques des satellites de haute résolution spatiale.

Le troisième chapitre, est consacré aux différentes techniques de segmentation des images. Nous fournirons la diversité des méthodes auxquelles la littérature scientifique fait référence.

Le dernier chapitre traitera du développement des différents critères d'évaluation des méthodes de segmentation des images utilisées ainsi que les trois méthodes que nous avons élaboré. Les trois techniques ont été appliquées à des images synthétiques et à des images satellitaires multispectrales. Les résultats obtenus ont été discutés permettant ainsi, de comparer les trois techniques et de quantifier leur apport.

La conclusion sera dédiée aux résultats les plus importants et à l'explication utilisées ainsi que la valeur ajoutée par notre travail.

Chapitre 1

Téledétection et analyse des images

1.1 Introduction :

La télédétection est une discipline scientifique qui comprend une variété de techniques et de compétences utilisées pour observer, analyser et interpréter les phénomènes terrestres et atmosphériques.

Qu'il s'agisse de l'observation visuelle de son environnement proche ou de l'observation à l'oeil nu des étoiles et des planètes, la télédétection est certainement l'une des plus vieilles activités de l'Homme. Aujourd'hui, cela nécessite une compréhension des nombreux processus physiques qui interviennent tout au long de la chaîne de mesure : Réception, traitement du signal, interaction onde/matière, source de rayonnement, propagation. La télédétection est principalement utilisée pour des recherches fondamentales en géophysique (océanographie, géologie, physique de l'atmosphère, géographie) ou pour des applications issues de ces domaines (végétales, ressources terrestres minérales et pollution), et cet outil a également d'autres utilisations dans le domaine de l'environnement.

Contrairement à ceux du début du développement de ces technologies, les systèmes de télédétection actuels ont connu des changements importants, en particulier au cours des dix dernières années, avec une technologie essentielle dans le suivi de plusieurs processus qui affectent la surface et l'atmosphère de la Terre. Un impact significatif sur notre planète, en particulier la déforestation, le changement climatique, la désertification, etc.

1.2 Télédétection :

La télédétection est la discipline dont l'objectif est d'obtenir des informations sur un objet, une zone ou un phénomène par l'analyse de données acquises par un dispositif qui n'est pas en contact physique avec l'objet étudié [11]. Les données collectées à distance peuvent être de nombreuses formes qui sont potentiellement disponibles à partir du champ d'énergie provenant de la surface de la Terre y compris les champs spectral, spatial et temporel [12].

La télédétection comprend tout le processus consistant à capter et à enregistrer l'énergie d'un rayonnement électromagnétique émis ou réfléchi, à traiter et à analyser les informations qu'il représente, puis à utiliser ces informations [13]. Elle peut être effectuée depuis un satellite, une plateforme aérienne (ballon ou avion) ou n'importe quel type d'instrument d'acquisition d'informations sur l'environnement. Bien que l'analyse des données de télédétection nécessite généralement des traitements numériques, des méthodes non numériques peuvent également être utilisées.

Aujourd'hui, les données de télédétection trouvent leur utilisation dans des applications aussi diverses en constante expansion et est de plus en plus utilisée comme source d'information pour les études de la transformation du globe à une échelle locale, régionale et même mondiale. Parmi ces applications, les applications terrestres incluent la cartographie régulière et thématique, la géologie, la prospection minière, la géomorphologie, la pédologie, l'agriculture, l'aménagement des territoires, l'urbanisme et la surveillance des catastrophes naturelles. Il existe d'autres applications non terrestres. Il y a celles concernant les études océanographiques (comme l'analyse de la couleur des océans, la mesure des températures de surface de la mer,...) ainsi que celles concernant l'étude de l'atmosphère (météorologie et climatologie).

la télédétection repose sur le fondement que différents matériaux réfléchissent et émettent les ondes électromagnétiques différemment en fonction, notamment, de leur matière, de leur couleur ou de leur rugosité. Bayoudh [14] rassemble deux modes d'acquisition principaux (figure1.1) :




FIGURE 1.1 – Principe général de la télédétection.

- Le mode passif, également désigné comme optique, implique la mesure de l'énergie émise et/ou réfléchie par la surface terrestre éclairée par une source d'énergie incidente naturelle, telle que le soleil. Lors de l'acquisition d'images multi-spectrales, également appelées images en couleur, l'énergie reçue est mesurée dans plusieurs bandes spectrales, qu'elles appartiennent ou non au domaine du visible. Ce mode d'acquisition présente l'avantage de fournir des données relativement simples à interpréter, surtout dans le domaine du visible. Cependant, lorsqu'il est dédié à l'observation de la surface terrestre, il est limité par la présence de nuages et de leur ombre projetée, entraînant des données manquantes dans les images ;
- En revanche, le mode actif, qui implique une source d'illumination artificielle et mesure l'énergie rétrodiffusée par l'objet cible, est utilisé dans l'imagerie radar. Bien que l'interprétation des données soit moins intuitive que pour l'imagerie optique et

nécessite des connaissances spécifiques en traitement du signal, ce mode d'acquisition présente l'avantage de ne pas être sensible au couvert nuageux en raison des gammes de longueurs d'onde élevées utilisées.

1.3 Acquisition des données de télédétection :

Les moyens d'acquisition des données de télédétection sont diversifiés et performants, englobant des techniques optiques, laser, radar, sismographie, gravimétrie, et autres. Les méthodes d'acquisition optiques reposent sur la mesure des rayonnements réfléchis ou émis par les cibles dans diverses fréquences (infrarouge, visible, etc.). Cela est possible grâce à l'émission ou la réflexion de rayonnements à différentes longueurs d'onde et intensités par les surfaces étudiées telles que l'agriculture, la forêt, les habitations, les surfaces d'eau, etc. Certains instruments, comme les sonars, utilisent des ondes sonores de manière similaire, tandis que d'autres mesurent des variations dans des champs magnétiques ou gravitaires.

Comme décrit dans [15], le processus de télédétection comprend généralement sept étapes clés (cf. figure 1.2) que nous rappelons ci-dessous.




FIGURE 1.2 – Les sept étapes du processus de télédétection selon [15]

1. Source d'énergie ou d'illumination (A) : La première condition essentielle de la

télédétection est une source d'énergie fournissant de l'énergie électromagnétique pour éclairer la cible. Le plus souvent, voire dans la quasi-totalité des cas, cette source d'énergie est le soleil. Cependant, le satellite lui-même peut être une source d'énergie, comme c'est le cas dans le domaine de la télédétection radar.

2. Rayonnement et atmosphère (B) : Au cours de son trajet "aller" entre la source d'énergie et la cible, le rayonnement interagit avec l'atmosphère. Une deuxième interaction se produit lors du trajet "retour" entre la cible et le capteur.

3. Interaction avec la cible (C) : Une fois parvenue à la cible, l'énergie interagit avec sa surface. La nature de cette interaction dépend des caractéristiques du rayonnement et des propriétés de la surface. Chaque objet géographique émet ou réfléchit un rayonnement dans différentes fréquences du spectre électromagnétique. On suppose en télédétection que tout objet ou classe d'objet sur la surface terrestre possède sa propre "empreinte digitale" dans le spectre électromagnétique (la signature spectrale), en fonction de la longueur d'onde du rayonnement qui est réfléchi ou émis par lui-même. Ainsi, une parcelle de canne à sucre aura des signatures différentes en fonction de son stade végétatif et de son niveau de maturation.

4. 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 non en contact direct avec la cible, mais embarqué à bord d'un satellite ou d'un avion, par exemple, pour être finalement enregistrée sous format numérique.

5. Transmission, réception et traitement (E) : L'information enregistrée par le capteur est ensuite transmise, souvent par des moyens électroniques, à une station de réception généralement située au sol, où l'information est transformée en images (numériques ou photographiques).

6. Interprétation et analyse (F) : Une interprétation visuelle et/ou numérique de l'image traitée est ensuite nécessaire pour extraire l'information souhaitée sur la cible.

7. Application (G) : La dernière étape du processus consiste à utiliser l'information extraite de l'image pour mieux comprendre la cible, c'est-à-dire la portion d'espace étudiée

(une ville, une zone inondée, une forêt, etc.), afin de découvrir de nouveaux aspects ou d'aider à résoudre un problème particulier.

1.3.1 Plateformes d'acquisition :

Pour enregistrer de manière adéquate l'énergie réfléchie ou émise par une surface ou une cible donnée, il est nécessaire d'installer un capteur sur une plateforme distante de la surface ou de la cible observée.

Ces plateformes peuvent être situées près de la surface terrestre, telles que le sol, un avion ou un ballon; ou à l'extérieur de l'atmosphère terrestre, comme sur un satellite ou un véhicule spatial .

On peut citer les plateformes comme suivante :

1.3.1.1 Plateformes terrestres :

Les plateformes terrestres, telles que les bras télescopiques fixés à des camions ou des véhicules tout-terrain, sont principalement utilisées à des fins d'expérimentation et d'étalonnage. Le capteur est généralement installé à l'extrémité de ces bras télescopiques.

1.3.1.2 Plateformes aériennes :

Ces plateformes se situent principalement sur des avions à ailes fixes, des hélicoptères et des ballons. Les avions sont souvent utilisés pour obtenir des couvertures aériennes détaillées de la surface terrestre.

Cependant, les avions présentent trois limitations majeures :

- la garantie de la prise répétitive des données n'est pas assurée;
- la zone couverte lors d'une mission est limitée;
- les coûts des produits sont relativement élevés.

1.3.1.3 Plateformes spatiales :

Dans l'espace, la télédétection est parfois effectuée à partir de la navette spatiale ou plus fréquemment, à partir de satellites en orbite autour de la Terre. Les satellites offrent

une couverture répétitive et continue de la surface terrestre en raison de leur orbite. Le coût joue souvent un rôle déterminant dans le choix des différentes plateformes.

1.3.2 Caractéristiques des satellites :

Bien que les plateformes terrestres et d'aéronefs puissent être utilisés, les satellites fournissent une grande partie de l'imagerie de télédétection couramment utilisée aujourd'hui. Les satellites ont plusieurs caractéristiques uniques qui les rendent particulièrement utiles pour la télédétection de la surface terrestre.

1.3.2.1 Orbite :

Le trajet suivi par un satellite est appelé son orbite. Les orbites des satellites dépendent de la capacité et de l'objectif des capteurs qu'ils transportent. La sélection de l'orbite peut varier en termes d'altitude (hauteur au-dessus de la surface de la Terre) ainsi que d'orientation et de rotation par rapport à la Terre.

1.3.2.1.1 Orbite géostationnaire :

Certains satellites, situés à une altitude élevée d'environ 36000 kilomètres, ont une orbite géostationnaire, leur permettant de regarder en permanence la même région de la surface terrestre. Cette configuration est utilisée par des satellites de communication et d'observation météorologique tels que METEOSAT (France), GOES (Geostationary Operational Environmental Satellites, USA), GMS (Japon), et INSAT (Inde) [16].

1.3.2.1.2 Orbite héliosynchrone :

Les satellites en orbite héliosynchrone passent toujours au-dessus d'un même point sur la surface de la Terre à la même heure. Cette orbite quasi polaire suit une trajectoire nord-sud, permettant au satellite de survoler les pôles à chaque révolution. Des satellites




FIGURE 1.3 – Satellite en orbite géostationnaire

tels que LANDSAT et SPOT utilisent cette orbite [17]




FIGURE 1.4 – Satellite en orbite héliosynchrone

1.3.2.1.3 Orbite ascendante et orbite descendante :

La plupart des satellites, en orbite quasi-polaire, se déplacent vers le nord d'un côté de la Terre et vers le sud de l'autre côté. Les deux passages du satellite sont respectivement appelés orbite ascendante et orbite descendante. Si l'orbite est également héliosynchrone, l'orbite ascendante se produit du côté ombragé de la Terre, tandis que l'orbite descendante se produit du côté éclairé par le Soleil.




FIGURE 1.5 – Satellite en Orbite ascendante et orbite descendante

Il offre l'avantage de passer à la même altitude au-dessus d'un point de la terre mais à des heures différentes. C'est le cas des satellites ERS-1 et ERS-2 [18] .

1.3.2.2 Couloir-couvert ou fauchée :

Lorsqu'un satellite est en orbite, le capteur observe une certaine partie de la surface, appelée couloir-couvert ou fauchée. La largeur de cette fauchée varie généralement entre quelques dizaines et centaines de kilomètres. Les satellites à orbite quasi-polaire semblent avoir une composante vers l'ouest due à la rotation de la Terre, permettant une couverture complète après un cycle orbital complet.

1.3.2.3 Points nadir :

Les points sur la surface de la Terre directement sous la trajectoire du satellite sont appelés les points nadir. La période nécessaire pour que le satellite revienne au-dessus d'un

point nadir aléatoire est définie comme le cycle de passage. Cette période ne doit pas être confondue avec la période de revisite, qui peut être beaucoup plus courte grâce aux capteurs orientables. Les satellites à orbite quasi-polaire offrent une couverture plus fréquente des régions de latitude élevée en raison de l'élargissement de la zone de chevauchement entre deux fauchées adjacentes.

1.4 Conclusion :

La télédétection est une discipline scientifique qui comprend une variété de techniques et de compétences utilisées pour observer, analyser et interpréter les phénomènes terrestres et atmosphériques.

Nous distinguons deux grands types de télédétection passive dans la source d'énergie est externe comme soleil et la source contrôler (interne) comme radar pour le mode active.

On ce qui nous concerne ce travail on s'intéresse à la cible qui en global l'utilisation et la couverture de sol, afin de pouvoir segmenter les frontières entre ces régions. Un ensemble des méthodes ont été développer.

Dans ce sens nous avons développé et appliquer de nouvelle méthode de segmentation des images satellitaires à haute résolution spatial.

Chapitre 2

Imagerie Satellitaire

2.1 Introduction :

Les images de télédétection sont les images capturées par divers capteurs à bord d'un engin spatial ou d'un aéronef. Chaque plateforme de télédétection a ses propres avantages et inconvénients. Les images des capteurs aéroportés présentent de nombreux avantages par rapport à leurs équivalents spatiaux et présentent en même temps de nombreuses limitations et inconvénients. Rees [19] discute brièvement mais exhaustivement des avantages et des inconvénients. En outre, le problème des déformations géométriques dans les images des capteurs aéroportés causé par la turbulence dans l'avion est le problème le plus critique. Trois types de mouvements d'aéronef appelés tangage, lacet et roulis entraînent des déformations géométriques dans les images.

L'imagerie satellitaire fournit maintenant des détails relativement moins chers, polyvalents et assez fréquents que jamais auparavant pour aider les chercheurs dans de nombreuses disciplines. Les images spatiales ont aussi le problème des distorsions géométriques mais moins sévères. Cependant, pour certaines applications, par ex. le repérage sur les terres agricoles, la résolution temporelle requise est beaucoup plus élevée que ce qui est disponible avec les plateformes satellites. En outre, l'acquisition de données multi-temporelles à partir de plateformes spatiales devient prohibitive. En outre, certaines applications telles que le repérage des cultures [20] ne sont pas gravement affectés par des déformations géométriques et ne nécessitent pas de couvrir de très grandes surfaces. Dans de tels cas, l'équipement d'imagerie se monte sur un avion-modèle à commande radio pour recueillir les données sur la zone cible rapidement et à plusieurs reprises selon les besoins. Les avions modèles radio-pilotés peuvent voler à des altitudes aussi basses que 100 mètres pour recueillir les

données avec les résolutions de quelques centimètres par pixel [21] .

Chaque plateforme ayant ses propres avantages et inconvénients, le compromis se situe entre le coût de la plateforme, la résolution spatiale, temporelle, spectrale et radiométrique des données qui sont affichées et interprétées comme une image.

2.1.1 Types des images de télédétection :

Les progrès récents dans le domaine de l'électronique ont permis au système de télédétection d'atteindre des images avec des résolutions au sol plus fines que jamais. Les images acquises à partir de la télédétection dépendent de la résolution spatiale du capteur, de la zone imagée sur la surface, du temps de révision et des bandes de longueur d'onde utilisées dans l'acquisition d'image. On cite les images selon les résolutions spatiales et spectrales [22] .

2.1.1.1 Classification spectrale :

En termes de régions spectrales utilisées dans l'acquisition de données, les images de télédétection sont divisées en trois grandes catégories :

- Images de radar à ouverture synthétique (SAR)
- Images optiques
- Images de détection de lumière et de distance (lidar)

2.1.1.1.1 Images de radar à ouverture synthétique (SAR) :

Ce sont les images synthétisées à partir des signaux radar capturés par un radar en mouvement à bord d'un engin spatial ou d'un avion. Les images radar étant le résultat de la diffusion d'une onde électromagnétique, la phase et l'amplitude portent de l'information hétérogène liée à l'occupation du sol, l'interaction avec le milieu diffusant (mécanismes de diffusion). Ceci permet notamment de remonter à des mesures physiques telles que la hauteur de la végétation, la topographie, le déplacement...etc

Sur la surface de la surface observée, ces images représentent l'énergie micro-ondes rétrodiffusé, dont les caractéristiques dépendent des propriétés de la surface, telles que sa pente, sa rugosité, son humidité, ses inhomogénéités de texture et sa constante diélectrique.

Cependant, les chercheurs exploitent les images SAR pour des études environnementales et des applications militaires. Matsuoka [23] explique l'utilisation de l'imagerie SAR dans l'évaluation des catastrophes naturelles, DiGiacomo Paul [24] décrit l'utilisation d'images SAR pour observer la pollution côtière et Mathiew [25] traite de l'utilisation de l'imagerie SAR pour la surveillance militaire.

Les images SAR peuvent être capturées à tout moment, en présence ou en absence de lumière du soleil, en toute saison ou conditions météorologiques. Les données SAR sont introduites dans des zones sans information sur les données optiques, c'est-à-dire les zones couvertes par les nuages et leurs ombres, fournissant des informations utiles sur la rugosité ou la structure de la surface. Par conséquent, les images SAR aident à différencier les types de couverture qui ne se distinguent pas par les images optiques en raison de leurs caractéristiques spectrales similaires. Cependant, les images SAR sont plus sensibles au bruit que leurs homologues optiques. Les images SAR souffrent généralement de niveaux sévères d'un bruit de mouche multiplicatif non gaussien.

2.1.1.1.2 Images optiques :

Les capteurs optiques capturent des images optiques de la surface de la terre dans des bandes infrarouges visibles, infrarouges et courtes ondes. Les longueurs d'ondes des bandes dans un système de télédétection optique se situent entre 0,30 mm et 15,0 mm. L'information radiométrique, spectrale, texturale, géométrique et contextuelle, contenue dans une image optique, sert généralement à l'interprétation d'image. Selon le nombre de bandes spectrales utilisées, les images optiques sont classées en quatre grandes catégories : Panchromatique (Pan), Multi-Spectral (MS), Super-Spectral (SS) et Hyper-Spectral (HS).

2.1.1.1.2.1 Images panchromatiques Le capteur est un détecteur à canal unique sensible aux rayonnements dans une large plage de longueur d'onde. Les capteurs panchromatiques collectent les rayonnements électromagnétiques pour toute la gamme du spectre visible et donnent une image en niveaux de gris. Les images panchromatiques sont obtenues à partir de l'enregistrement du rayonnement dans un unique intervalle de longueur d'onde situé dans le domaine du visible, c.-à-d. entre 0,4 et 0,7. Comme les données ne sont acquises que dans un seul canal, seules des images en noir et blanc peuvent être obtenues (si l'image

est codée sur 8 bits, elle sera visualisable en 255 niveaux de gris). Bien que moins riche du point de vue de la résolution spectrale, l'image panchromatique offre une résolution spatiale plus importante.

Les caractéristiques liées aux caractéristiques spatiales ou de forme des images satellites sont extraites des images panchromatiques. Les images PAN ont toujours plus de résolutions que les images MS du même satellite.

Des exemples de systèmes d'imagerie panchromatique sont IKONOS PAN et SPOT HRV-PAN.

2.1.1.1.2.2 Images multi-spectrales : Le capteur d'un système d'imagerie multi-spectral est obtenu à partir d'un ensemble de capteurs multi-bande (moins de 10 bandes). L'imagerie multi-spectrale fait généralement référence à des groupes 3 à 10 bandes qui sont représentées en pixels. Chaque bande est acquise à l'aide d'un radiomètre de détection à distance.

Par rapport au système d'imagerie panchromatique, le rayonnement enregistré d'un système d'imagerie multi-spectral se situe dans une gamme étroite de longueur d'onde pour chaque bande. La représentation par combinaison de ces bandes d'information numérique en utilisant les trois couleurs primaires (rouge, vert, bleu) permet d'obtenir des images en couleurs. Les données de chaque bande sont représentées comme une couleur primaire et, selon la luminosité relative (c.-à-d. valeur numérique) de chaque pixel dans chaque bande, les couleurs primaires se combineront en proportions différentes pour produire des couleurs distinctes. Les informations de luminosité et de spectre (couleur) des cibles observées sont disponibles sur l'image résultante. Quoi qu'il en soit, les images multi-spectrales ont une faible résolution, elles peuvent couvrir la gamme visible et infrarouge des longueurs d'ondes.

Des exemples de systèmes multi-spectral sont LANDSAT MSS, LANDSAT TM, SPOT HRV-XS et IKONOS MS

2.1.1.1.2.3 Images super-spectral et hyper-spectral : Un système d'imagerie est considéré comme super-spectral s'il acquiert plus de dix bandes spectrales. Il sera hyper-spectral, si le nombre de bandes spectrales capturées est supérieur à cent. Les largeurs de bande sont plus étroites lorsque le nombre de bandes spectrales augmente. Ainsi, les capteurs pourront capter les caractéristiques spectrales plus fines des caractéristiques

des cibles. Ces types de systèmes permettront d'améliorer la compréhension de la dynamique et des processus mondiaux sur la terre, dans les océans et dans la basse atmosphère.

Chaque pixel d'une image hyper-spectrale contient l'information recueillie dans de grandes fenêtres d'acquisition étalées sur la totalité du spectre visible et infrarouge.

La quantité d'information à stocker et à traiter est donc énorme et requiert des capacités de calcul bien plus importantes que dans le cas des images multi-spectrales.

Des exemples de système de télédétection optique super-spectrale sont MODIS (36 bandes spectrales) et MERIS (15 bandes spectrales programmables), et d'un hyper-spectral est Hyperion (242 bandes spectrales). Les applications de ces images sont bien entendu multiples. Parmi les plus importantes, on peut citer la géologie (identification des minéraux...), l'agriculture de précision, la foresterie (état sanitaire, identification d'espèces...) ou la gestion des milieux aquatiques (qualité des eaux, composition en phytoplancton...).

2.1.1.1.3 Images de détection de lumière et de distance (lidar) :

Dernièrement, il y a eu un rapprochement entre les champs optiques et radar, manifesté non seulement sous le point de vue spectral, mais surtout dans le mode de conception et de fonctionnement des systèmes. Ces systèmes, appelés Lidar, se développent en raison de la progression des lasers, qui exploitent les propriétés spatiales, spectrales et temporelles. Lidar, qui représente la détection et la portée de la lumière, a reçu une large acceptation dans l'arpentage aérien comme un outil de premier plan pour obtenir des données de surface de haute qualité dans un délai de réponse sans précédent. Lidar est une technologie de balayage laser qui utilise un émetteur de lumière laser et des capteurs pour mesurer la distance entre l'avion et le sol, y compris des objets tels que les bâtiments et la végétation. Les systèmes Lidar, de nos jours, font des mesures de portée avec un nombre croissant de points par surface, comptent plusieurs retours par tour unique, fournissent des valeurs de réflectance de la surface éclairée et captent la hauteur du terrain et des objets tels que les bâtiments, dans des détails de résolution étonnants. Airborne Lidar est maintenant la méthode la plus utilisée pour la cartographie rapide et précise du terrain.

En tant que SAR, le Lidar émet une lumière laser sur une cible au sol et reçoit une fraction du rayonnement réfléchi par la cible. Le signal reçu porte l'information du temps pris en aller-retour, l'intensité et la phase de l'écho. La fréquence de la lumière laser utilisée dans

Lidar est habituellement dans la gamme ultraviolette, visible ou infrarouge proche [26] . Dans certaines applications de télédétection, plusieurs faisceaux lumineux à différentes fréquences sont utilisés. Ulrich [27] est utilisé un lidar à faisceau multiple aéroporté pour détecter les déversements d'hydrocarbures et les algues. Le système Lidar peut également détecter plus d'un écho de la même impulsion afin qu'il puisse visualiser à travers l'eau, les auvents et les arbres sur le sol pour cartographier le terrain de surface et pour estimer la profondeur du plan d'eau ou de la plantation.

2.1.1.2 Classification spatiale :

La résolution des images numériques est définie par le nombre de pixels par millimètres. En télédétection, on exprime la résolution des images par la taille de la zone couverte par un pixel. Chaque pixel de l'image correspond à une partie de la surface de la terre. On parle alors de "résolution-sol".

En termes de résolution spatiale, les systèmes d'imagerie satellitaire peuvent être classés en : systèmes à faible résolution (environ 1 km ou plus), systèmes de résolution moyenne (environ 100 m à 1 km), systèmes haute résolution (environ 5 m à 100 m) et des systèmes à très haute résolution (environ 5 m ou moins). La résolution spatiale du capteur panchromatique Ikonos, par exemple, est de 1 m. La surface au sol représentée par des pixels à la surface directement sous le satellite, appelée point nadir, a une échelle plus grande que les pixels qui sont hors-nadir. Pour montrer l'importance des détails obtenus en haute résolution, par exemple, comparer un ensemble d'images simulé correspondant à différentes résolutions.

2.1.1.2.1 Faible résolution :

Les satellites à faible résolution se caractérisent par une résolution spatiale d'environ 1 km assurant une couverture quotidienne régulière. Ces données sont obtenues uniquement en mode multi-spectral incluant une partie visible et infrarouge du spectre optique. Ces données sont utiles pour la cartographie étendue, globale et continentale, les besoins de couverture régulière, y compris la surveillance de la température de la surface de la mer, la surveillance de l'atmosphère et de l'océan, la surveillance des conditions de végétation, la vigueur régionale de la végétation et les études sur la sécheresse, la surveillance des grandes catastrophes, la couverture de neige et la surveillance des glaciers. Des exemples satellites à

faible résolution sont :

- Meteosat MSG : capture de 7 bandes de résolution de 40 km à l'aide du capteur GERB,
- SPOT 5 : capture de 4 bandes de résolution de 1 km à l'aide du capteur VEGETATION 2 et
- OrbView-2 : capture de 8 bandes de résolution de 1,13 km à l'aide du capteur SeaWiFS.

2.1.1.2.2 Résolution moyenne :

Les satellites à moyenne résolution fournissent généralement une couverture hebdomadaire mensuelle. Ces données ont des résolutions spatiales de 100m à 1km et des bandes spectrales allant du bleu clair à l'infrarouge à courte impulsion. Des zones relativement importantes sont couvertes par chaque passage supérieur par satellite. Ces données sont adaptées à une variété d'utilisations d'informations impliquant la cartographie, la surveillance et la détection de la couverture terrestre et des caractéristiques de l'utilisation du sol.

Les données de télédétection avec une résolution spatiale moyenne peuvent fournir des informations utiles sur la production primaire brute, en particulier sur l'échelle des zones urbaines. Cependant, As-syakur et al [28] ont comparé l'impact de la résolution spatiale sur la détection de divers écosystèmes montre que les images de haute résolution spatiale ont fourni des estimations plus précises de la production primaire brute maximale que les estimations dérivées de la résolution spatiale moyenne. L'objectif principal, présenté dans [29] , est d'examiner et de comparer l'efficacité de deux algorithmes avancés pour l'estimation de surfaces imperméables à partir d'images satellitaires de résolution spatiale moyenne, à savoir l'analyse linéaire de mélange spectral et le réseau neuronal artificiel.

Les exemples satellites de résolution spatiale moyenne sont les suivants :

- Envisat : capture de 15 bandes de résolution de 300 m en utilisant le capteur MERIS,
- RESURS-01-1 : capture de 2 bandes de résolution de 240 m en utilisant le capteur MSU-S et
- IRS-1C : capture de 2 bandes de résolution de 188 m en utilisant le capteur WiFS.

2.1.1.2.3 Haute et très haute résolution

Les satellites à haute résolution spatiale sont caractérisés par une résolution de pixels supérieure à 1 m ; Contrairement à une résolution spatiale très élevée où la résolution est

inférieure à 1 m. Ces données sont obtenues uniquement en mode panchromatique, plus souvent en combinaison avec le mode panchromatique et multi-spectral. Les images peuvent être collectées sur une zone particulière tous les 1 à 3 jours, mais à des angles de vue très variables. La majorité des satellites possèdent les systèmes les plus modernes avec une grande flexibilité et une capacité à obtenir des données selon les demandes très concrètes.

Les images haute résolution spatiale trouvent de plus en plus d'applications dans tous les domaines. Petri et al [30] ont proposé une méthode d'extraction complète du réseau routier urbain à partir d'images de résolution spatiale très élevées. Vasques et al[31] sont utilisés des ressources de données, à partir de capteurs satellitaires à haute résolution spatiale, pour étudier l'identification et la planification des zones urbaines (taille, infrastructure, emplacement, etc.). Les applications typiques incluent : les modèles de villes 3D, les études urbaines, la cartographie de la végétation dispersée, l'agriculture de précision, le contrôle des activités agricoles, l'inventaire forestier, la surveillance d'un lac glaciaire, la surveillance des mines ouvertes, la cartographie de l'érosion des sols, la planification et la conception d'infrastructures linéaires, La cartographie des infrastructures de transport, l'industrie de l'assurance, la cartographie des bâtiments détruits par un séisme et la planification et l'organisation de l'aide humanitaire.

Il existe des satellites de haute résolution spatiale bien connus comme SPOT-5, Ikonos, QuickBird, WorldView-1, WorldView-2 et GeoEye-1.

2.1.2 Caractéristiques des satellites de haute résolution spatiales :

L'imagerie de télédétection trouve de plus en plus d'acceptabilité et d'utilisation. Les satellites de télédétection sont généralement placés dans des orbites polaires solaires, où le satellite transmet toutes les latitudes au même moment solaire local chaque jour. Les orbites se situent à moins de 20 degrés d'une inclinaison de 90 degrés de l'équateur. Pour introduire des applications de télédétection, les propriétés des images satellitaires doivent être connues à l'avance. Par conséquent, cette section met en lumière certains des satellites à très haute résolution spatiale.

2.1.2.1 Satellite IKONOS :

Le lancement du satellite IKONOS (1999) a marqué l'histoire car il s'agit du premier satellite commercial avec une résolution de 1m. IKONOS produit des images en noir et blanc (panchromatique) avec une résolution de 82 centimètres et des images multi-spectrales avec une résolution de 4 mètres. Les images provenant des deux capteurs peuvent être fusionnées pour créer des images couleur à 1 mètre. IKONOS est le premier capteur civil de très haute résolution (1 mètre) offrant des images comparables aux photos aériennes. Le premier satellite d'Ikonos a été perdu lors du lancement, mais le second est encore opérationnel. La très haute résolution permet de visualiser les bâtiments, les routes ou même les arbres et est donc très utile pour les applications telles que la cartographie urbaine, l'utilisation des terres, l'agriculture ou la gestion des catastrophes naturelles.

Mode	Canal	Bande spectral	Résolution spatial
Panchromatique		0,45-0,90 μm (vis et proche infrarouge)	1 m
Multi-spectral	1	0,45-0,52 μm (bleu)	4 m
	2	0,52-0,61 μm (vert)	4 m
	3	0,64-0,72 μm (rouge)	4 m
	4	0,77-0,88 μm (proche infrarouge)	4 m

TABLE 2.1 – Résolutions spatial et spectral du Satellite IKONOS .

2.1.2.2 Satellite QuickBird :

QuickBird est un satellite commercial lancé le 18 octobre 2001 offre la combinaison d'une résolution spatiale très élevée, d'une capacité importante de stockage à bord et d'un haut degré de précision pour le géo-référencement. Le satellite QuickBird est capable d'acquérir des images sur plus de 75 millions de kilomètres carrés par an. Sa large bande de fauchée, combinée avec une grande capacité de stockage à bord et une bonne précision de géolocalisation, lui permet d'acquérir efficacement et avec précision des images de vastes zones du globe.

Le satellite collecte des images panchromatiques à une résolution de 0,6 mètres et des images multi-spectrales à des résolutions de 2,4 mètres. À cette résolution, les bâtiments et

d'autres infrastructures sont facilement visibles. Cependant, cette résolution est insuffisante pour travailler avec des objets plus petits.

Mode	Canal	Bande spectral	Résolution spatial
Panchromatique		0,45-0,90 μm (vis et proche infrarouge)	0,6 m
Multi-spectral	1	0,45-0,52 μm (bleu)	2,4 m
	2	0,52-0,60 μm (vert)	2,4 m
	3	0,63-0,69 μm (rouge)	2,4 m
	4	0,76-0,90 μm (proche infrarouge)	2,4 m

TABLE 2.2 – Résolutions spatial et spectral du Satellite QuickBird .

2.1.2.3 Satellite GeoEye-1 :

Le satellite GeoEye-1 lancé en 2008 est le satellite commercial fournissant les images de la terre avec la meilleure résolution au monde. Ce satellite agile peut tourner ou faire pivoter vers l'avant, vers l'arrière ou côte à côte avec une précision robotique et a une capacité de retour de 1 à 3 jours selon la latitude.

Le satellite capture simultanément des images numériques panchromatiques (couleur noir et blanc) de 0,41 m et des images numériques multi-spectrales (couleur) de 1,65 m. Le satellite GeoEye-1 collecte des images au nadir avec une résolution de 0,41m en panchromatique (noir et blanc) et de 1,65m en multi-spectral (bleu, vert, rouge et proche infrarouge). Le détail et la précision géo-spatiale des images étendent davantage les applications des images satellites dans le secteur commercial et gouvernemental.

Les jeux de données panchromatiques et multi-spectrales sont disponibles séparément ou peuvent être achetés sous forme d'images multi-spectrales combinées (pan-aiguës) de 0,41 m. La précision en position est la meilleure de tous les satellites disponibles commercialement, à savoir une précision de 3m.

Mode	Canal	Bande spectral	Résolution spatial
Panchromatique		0,45-0,80 μm (vis et proche infrarouge)	0,41 m
Multi-spectral	1	0,45-0,51 μm (bleu)	1,65 m
	2	0,51-0,58 μm (vert)	1,65 m
	3	0,65-0,69 μm (rouge)	1,65 m
	4	0,78-0,92 μm (proche infrarouge)	1,65 m

TABLE 2.3 – Résolutions spatial et spectral du Satellite QuickBird .

2.2 Conclusion :

Le traitement d'image concerne l'analyse et la compréhension de l'image dans le but d'en extraire des informations utiles. Il cherche aussi parfois à comprimer l'image, afin de gagner en vitesse lors de la transmission de l'information, et en capacité de stockage, tout en dégradant le moins possible les images considérées. D'abord nous avons parlé dans ce chapitre les différents types des images numériques et leurs caractéristiques les plus importantes.

Puisque, la télédétection est un domaine de recherche récent en pleine expansion qui couvre une large palette d'applications. La littérature est riche en travaux de recherche portant sur la détection du bâti, des réseaux routiers, des zones de végétation, de l'analyse de dégâts, etc. La quasi-totalité de ces approches intègre la segmentation d'images comme étape fondamentale dans le processus d'extraction automatique de l'information. Dans ce chapitre, nous avons rappelé le principe général du processus d'acquisition des données de télédétection, ses plateformes et caractéristiques de satellite ainsi que le différent type de données manipulées à savoir les images de télédétection et leurs propriétés.

Les satellites de télédétection tels que Ikonos, QuickBird et GeoEye-1 fournissent des images Pan et MS avec une haute résolution spatiale. Ces images sont de plus en plus utilisées dans plusieurs domaines et la segmentation de ces images est notre travail dans cette thèse. Les caractéristiques énoncées dans ce chapitre sont à la base de la plupart des procédés de traitement d'images, notamment les méthodes de segmentation d'images qui feront l'objet de chapitre qui suit.

Chapitre 3

Segmentation des images numériques

3.1 Introduction :

Dans la vision par ordinateur , la segmentation d'image est le processus de partitionnement d'une image numérique en plusieurs segments (ensembles de pixels, également appelés super-pixels). Le but de la segmentation est de simplifier et / ou de changer la représentation d'une image en quelque chose de plus significative et plus facile à analyser.

La segmentation d'image consiste à partitionner l'image en un ensemble de régions connexes. L'intérêt de ces régions est de pouvoir être manipulée ensuite via des traitements de haut niveau pour extraire des caractéristiques de forme, de position, de taille, etc. Le problème est évidemment très mal posé, car on ne sait jamais dire quelle est la segmentation idéale. L'idée est bien sûr que la région se rapproche de la notion d'objet, au sens courant du terme. Néanmoins, on peut dégager des propriétés plus raisonnables qu'on cherche à obtenir dans un algorithme de segmentation, en particulier[\[32\]](#) :

- Stabilité : la segmentation obtenue ne doit pas varier beaucoup lorsque les conditions d'acquisition varie légèrement (bruit, illumination, point de vue,...)
- Régularité : les régions obtenues doivent être simples à manipuler (taille suffisante, forme régulière,...)

Certaines des applications pratiques de la segmentation d'image sont :

- Récupération d'images basée sur le contenu
- Intelligence artificielle
- Télédétection

- Imagerie médicale
- Détection d'objet
- Tâches de reconnaissance
- Systèmes de contrôle de la circulation

D'après Zucker [33], la segmentation, est définie comme suit : Segmenter une image I en n régions, revient à la partitionner en n sous-ensembles $R_1, R_2, \dots, R_n$ tel que aucune région ne doit être vide, l'intersection entre deux régions doit être vide et l'ensemble des régions doit reprendre toute l'image. Une région est l'ensemble de pixels connexes ayant propriété communes qui les différencient des pixels des régions voisines. Cette définition se décrit mathématiquement par suivante :

1. $I = \bigcup_i R_i$

2. R_i constituée de pixels connexes pour tout i .

3. $P(R_i) = \text{vrai}$ pour tout i .

4. $P(R_i \bigcup R_j) = \text{faux}$ pour tous $i, j, R_i \text{ et } R_j$ étant adjacent en I .

- $P(.)$ désigne un prédicat d'homogénéité.

La première condition indique que chaque pixel de l'image doit appartenir à une région R_i et l'union de toutes les régions formes de l'image entière. La deuxième condition est relative à la structure des régions, elle définit une région comme un ensemble de pixels qui doivent être connexes. La troisième condition exprime que chaque région doit respecter un prédicat d'uniformité. La dernière condition implique le non réalisation de ce même prédicat pour la réunion de deux régions adjacentes.

3.2 Techniques de segmentations d'images :

A cause des problèmes d'ambiguïtés et du bruit qui affectent certains pixels de l'image au sein de l'opération de segmentation, les chercheurs proposent plusieurs techniques de segmentation d'image.

OUARDIA [34] est distingué trois grandes approches de segmentation :

3.2.1 Segmentation par l'approche « régions » :

Les méthodes basées sur l'approche régions consistent à partitionner l'image traitée en régions homogènes [35] . Ces régions sont composés d'ensemble des pixels connexes possédant des propriétés au sens d'un prédicat d'homogénéité donné.

En plus, l'information niveau de gris et l'information spatiale sont automatiquement intégrées dans le processus de segmentation [36] . Le problème principal lié à cette méthode est associé à la définition du critère d'homogénéité utilisé dans le processus de segmentation de l'image. On distingue les méthodes de cette approche.

3.2.1.1 Croissance des régions :

Cette méthode choisit initialement un pixel ou un ensemble des pixels, appelé germe ou noyaux des régions à partir desquels la croissance des régions s'effectuera. Les régions sont construites en ajoutant successivement à chaque germe les pixels qui lui sont connexes et qui respectent un critère d'uniformité ou d'homogénéité. La Croissance s'arrête lorsque

tous les pixels ont été traités.




FIGURE 3.1 – Principe de la segmentation par croissance des régions

La littérature en traitement d'image est riche en méthode de segmentation par croissance de régions[37][38].

3.2.1.2 Division des régions :

L'approche segmentation par division de régions consiste à diviser l'image originale en régions homogènes au sens d'un critère donné.

Le processus de cette méthode est récursif et considère que la région initiale correspond à l'image à analyser. Si une région ne respecte pas un prédicat d'homogénéité, elle est divisée en quatre sous-régions de taille égale. Chaque sous-région est ensuite analysée, ce processus de division se poursuit pour toutes les zones nouvellement créées et ne s'arrête que lorsque toutes les zones sont homogènes ou bien leurs tailles sont en dessous d'un seuil fixé préalablement. A cause des divisions en quatre régions, cette méthode est plutôt adaptée à des images carrées ayant un nombre de lignes et de colonnes égal à une puissance de deux, et dans lesquelles les régions sont de forme rectangulaire. D'autre part, cette méthode a tendance à faire apparaître des effets de blocs.

La division de l'image est généralement représentée par une structure géométrique

bien particulière telle que la structure à arbre quaternaire « quadtree » ou la structure de Voronoï. La figure (3.2) montre le principe de la segmentation par division suivant la structure d'arbre quaternaire.




FIGURE 3.2 – Principe de la segmentation par division des régions (Structure quaternaire)

Le critère d'homogénéité peut être évalué par la variance des niveaux de gris ou peut être défini à partir de l'allure l'histogramme de niveau de gris. Par exemple dans [39] , l'histogramme de chaque région est analysé, si il est unimodal (région homogène), la région reste inchangée, sinon elle est divisée. La division prend fin quand toutes les régions ont un histogramme unimodal.

3.2.1.3 Fusion de région (Bottom-Up) :

Dans les images, chaque pixel $P(x,y)$ a quatre voisins horizontaux verticaux et quatre voisins diagonaux.



FIGURE 3.3 – Les 8 et 4 voisins de $P(x,y)$

L'approche par fusion des régions [40] , est ascendante telle que tous les pixels sont visités. Pour chaque voisinage de pixels, un prédicat P est testé. Si P est vérifié, les pixels

correspondants sont regroupés dans une région. Après le parcours de toute l'image, les groupes de voisinages se voient appliquer le même test, et sont réunis si P est vérifié.

Le processus est itéré jusqu'à satisfaction d'un certain critère d'arrêt [41]. Elles suivent une hiérarchie arborescente comme montrée dans la figure (3.4) Leurs inconvénients majeurs c'est que le résultat final (image segmentée) dépend fortement du choix des régions de départ.




FIGURE 3.4 – Hiérarchie de la méthode de segmentation par fusion

3.2.1.4 Division/fusion « Splitting and Merging » :

La méthode division/fusion se présente en deux étapes :

Division : le processus consiste à diviser l'image en région, considère l'image comme une région initiale. Chaque région est analysée, puis l'heuristique d'homogénéité est évaluée. Si la région ne vérifie pas l'heuristique, alors elle est divisée en plusieurs sous-régions. Cette opération est répétée sur chaque sous-région.

Fusion : dans cette étape, l'heuristique de l'homogénéité est évaluée pour tous les couples de régions voisines. Si la fusion de deux régions vérifie cette heuristique, elles sont fusionnées.

[42] sont les premier qui proposer cette méthode en 1976, à partir de laquelle de nouvelles versions sont proposées dans la littérature [43], [44] et [38].




FIGURE 3.5 – Principe de la segmentation par division/fusion

3.2.1.5 Classification :

Les classes sont construites à partir des attributs des pixels. Chaque pixel est affecté à une classe unique. Cette affectation peut être effectuée en basant sur des régions dont on connaît les classes d'appartenance a priori. Lorsque le niveau de gris considéré comme la seule attribut qui indique un pixel, la méthode de classification peut être abordée par des techniques de seuillage.

La classification des intensités lumineuses s'effectue en général à partir du calcul d'histogramme de répartition dans l'image. Les différents modes de l'histogramme et les vallées correspondantes sont recherchés. On détermine alors les classes par les intervalles entre les vallées. On définit ensuite les régions par les ensembles maximaux de points images connexes appartenant à la même classe. La figure(3.6) illustre un histogramme à trois modes.




FIGURE 3.6 – Histogramme de répartition à trois modes

3.2.1.5.1 Classification supervisée :

Elle s'opère à partir de la connaissance de chacune des classes définies par une approche probabiliste. Elle se base sur l'apprentissage de propriétés discriminantes sur un échantillon de données déjà classées. Citons, par exemple, les réseaux de neurones artificiels.

3.2.1.5.1.1 Réseaux de neurones artificiels : La structure d'un neurone artificiel est illustrée dans la figure(3.7). Les blocs rectangulaires représentent les entrées multipliées par des poids W_i , F correspond à la fonction de classification (de segmentation) et z correspond à la somme linéaire des poids multipliés par les entrées correspondantes. Un réseau peut être créé en augmentant le nombre de neurones et de sorties avec l'ajout de blocs elliptiques ($F(z)$) horizontalement et verticalement.




FIGURE 3.7 – Structure d'un neurone

En segmentation d'images, les réseaux de neurones sont utilisés comme classifieurs[45]. Les poids W_i sont déterminés par apprentissage sur une base d'images dont les résultats de segmentations sont connus.

3.2.1.5.2 Classification non supervisée :

Elle vise à séparer automatiquement l'image en clusters sans aucune connaissance à priori sur les classes. Elle se base sur une mesure de distance entre les vecteurs d'attributs.

3.2.1.5.2.1 Classification par analyse hiérarchique d'histogramme 2D : Les méthodes de classification par analyse histogramme présentent l'avantage d'effectuer la

segmentation sans connaître à priori les images.

En particulier la classification par analyse hiérarchique d'histogramme 2D présente un intérêt par rapport aux autres méthodes de classification, elle n'exige pas de requantification colorimétrique des images, elle est tolérante sur les valeurs de ses paramètres et présente une certaine résistance au bruit [46].

[46] proposent une décomposition hiérarchique de l'histogramme 2D qui se divise en deux phases : la première concerne l'apprentissage et la deuxième concerne la décision.

1. Phase d'apprentissage

Elle compte sur une décomposition hiérarchique des niveaux de gris en image J . Pour chaque niveau de gris p_n de l'image J , Les pixels P_i sont identifiés par des composants connectés avec des valeurs de pixel supérieures ou égales à p_n . Chaque pic est par la suite décomposé de manière itérative en pics plus étroits, du niveau de gris 0 au niveau de gris 255.

Un pic est considéré comme significatif s'il représente une population supérieure ou égale à un seuil S (exprimé en pourcentage de la population totale sur l'image I).

la figure(3.8) exposant le principe de la décomposition hiérarchique de l'image d'histogramme en réalisant une arborescence des pics représentatifs des classes. En rouge, sont les noeuds (5 noeuds) effectivement construits, les feuilles encerclées par un cercle correspondent aux pics reconnus (trois feuilles K_2 , K_3 et K_4). En noir, sont les branches explorées et les noeuds ou les feuilles non retenues en raison d'un effectif en dessous du seuil S . Le nombre de classes N_c équivaut au nombre de feuilles retenues (la classe correspondant aux feuilles K_i est noté C_i). Par suite N_c dépend du seuil S .

2. Phase de décision

La phase de décision consiste en un reclassement des pixels non affectés aux pics au moyen de la distance colorimétrique. Dans cette séquence, le centre de masse $\mu(K_i)$ de chaque noyau K_i peut être calculé en l'espace 2D des couleurs. Désignons par la




FIGURE 3.8 – Un exemple de décomposition hiérarchique. Les feuilles encadrées (partie b) correspondent à des pics significatifs tels qu'obtenus à l'issue de la décomposition itérative (traits pleins en partie a), tandis que les feuilles marquées $< S$ (partie b) correspondent à des pics non significatifs (en pointillés en partie a)

couleur correspondant au point de coordonnées $(x_1; x_2)$ dans l'espace 2D des couleurs.

Deux cas sont possibles :

- Si (x_1, x_2) appartient à K_i , la couleur β est attribuée à la classe C_i .
- Sinon, soit P_k le pic dont il fait partie (x_1, x_2) , la couleur β est assignée à la classe C_i correspondant à la feuille retenue K_i descendant de P_k , tel que $d[\mu(K_i); (x_1; x_2)]$ est minimale, où $d[a, b]$ correspond à la distance entre a et b .

La mesure de la distance joue un rôle important dans tous les types de méthodes de classification. De façon générale, la distance $d[a, b]$ se traduit comme suit :

$$dist^2 = (\beta - \mu_i)^t M (\beta - \mu_i) \quad (3.1)$$

où M est la matrice qui détermine la métrique et t l'opérateur de transposition

métrique. De divers choix de métriques sont possibles. On peut considérer le choix d'une métrique comme l'un des paramètres pertinents de l'algorithme proposé. Pour notre travail, nous avons pratiqué deux métriques simples et bien connues : la métrique Euclidienne et la métrique Mahalanobis.

(a) **Distance euclidienne :**

La distance euclidienne est définie comme suite en posant : $M = Id$, où Id est la matrice identité. Avec métrique euclidienne, la frontière entre deux classes C_i et C_j est située sur la ligne perpendiculaire à la droite reliant C_i à C_j .

(b) **Distance de Mahalanobis :**

La distance de Mahalanobis est l'une des techniques fondamentales et très employée en tant que mesure de distance pour la classification [47]. Elle est définie en posant : $M = (C_v)^{-1}$, où $(C_v)^{-1}$, représente l'inverse de la matrice de covariance de la classe C_i . Avec la métrique de Mahalanobis, la frontière entre deux classes C_i et C_j est quadratique, c'est-à-dire une hyperbole ou une ellipse. Si la matrice de covariance est la matrice identité, la distance de Mahalanobis est égale à la distance euclidienne. Si la matrice de covariance est diagonale, on obtient la distance euclidienne normalisée.

3.2.2 Segmentation par l'approche «contours »

D'abord, un contour est un ensemble de pixels réalisant une frontière entre deux ou plusieurs régions voisines, il est défini comme le lieu de variation significative de l'information "niveau de gris, couleur et texture". Dans la segmentation par l'approche contour, il s'agit d'identifier les discontinuités entre les différentes régions de l'image. Cette approche cherche des dissimilarités. Elle permet de détecter les transitions entre les régions de l'image.

L'approche contour n'aboutit pas forcément à une segmentation, car les contours détectés ne sont pas toujours connexes. Il existe cependant des techniques qui permettent à ces méthodes d'avoir des contours fermés.

3.2.2.1 Processus « classique » de détection de contours :

Le processus classique de détecteur de contours suit les étape suivante[48] :



FIGURE 3.9 – Le processus classique de détection de contours

La mise en évidence des contours :

C'est une première étape importante, car elle permet de marquer les contours. Cette mise en évidence s'obtient par exemple par une différentiation (dérivation) de l'image.

La réduction des contours :

Elle agit de manière à ce que les contours mis en évidence ne fassent qu'un seul pixel d'épaisseur.

La binarisation des contours :

Elle permet d'obtenir une image contours binaire. La binarisation est une étape clef. Elle définit quels sont les contours que l'on considère comme importants et quels sont ceux que l'on rejette.

La description des contours :

Elle permet d'organiser les points de contours en structures simples tels les segments de droites, arcs de cercle, etc., et de détecter les contours fermés afin de les séparer.

Les méthodes de cette approche s'appuient sur la détection des discontinuités dans l'image et peuvent être divisées en trois classes : les méthodes dérivatives, les méthodes analytiques et les méthodes déformables [49].

3.2.2.1.1 Méthodes dérivatives :

Elles consistent à calculer la dérivée en chaque point de l'image afin de mettre en évidence les variations de niveau de gris.

L'allure de la dérivée première et de la dérivée seconde d'un signal de type « saut d'amplitude », qui peut correspondre à une variation locale et dans une seule direction du niveau de gris, est donnée par la figure(3.10) suivante.




FIGURE 3.10 – Contour et ses dérivées

Une zone de transition dans le signal correspond à un maximum (ou un minimum) local de la dérivée première et un passage par zéro de la dérivée seconde. L'identification d'une zone de transition dans l'image peut être ainsi faite par seuillage de la norme de sa dérivée première ou du passage par zéro de sa dérivée seconde.

De nombreuses techniques d'extraction de contours existent dans la littérature. Elles peuvent être classées comme suit [50] :

- Les algorithmes basés sur le gradient (ou opérateurs du premier ordre).
- Les algorithmes basés sur le Laplacien (ou opérateurs du second ordre).
- Les algorithmes utilisant des filtres sophistiqués.

L'approche gradient

Une image (continu/analogique) peut être considérée comme une fonction $f(x, y)$ où :

x et y sont les coordonnées d'un point, et $f(x, y)$ est l'intensité de l'image en ce point.

Ce type de détection de contour se base sur la première dérivée de l'image I en chacun de ces points dans les deux directions horizontale et verticale. Un point de contours aura une amplitude $A(x, y)$ et une direction $Dir(x, y)$:

$$\vec{\nabla} = \begin{pmatrix} \frac{\partial f(x, y)}{\partial x} \\ \frac{\partial f(x, y)}{\partial y} \end{pmatrix} \quad (3.2)$$

$$A(x, y) = \sqrt{\left(\frac{\partial f(x, y)}{\partial x}\right)^2 + \left(\frac{\partial f(x, y)}{\partial y}\right)^2} \quad (3.3)$$

$$Dir(x, y) = \arctan \frac{\frac{\partial f(x, y)}{\partial x}}{\frac{\partial f(x, y)}{\partial y}} \quad (3.4)$$

Ces opérations sont valables pour une image continue, mais pour une image numérique/discrète, le calcul du gradient devient impossible car une fonction discrète n'est pas dérivable. La solution généralement adoptée est l'estimation du gradient par des différences finies.

Théoriquement, le gradient d'un point à une direction donnée qui peut se situer dans l'intervalle $[00 - 360^\circ]$. Mais chaque pixel n'a que 8 pixels voisins, ce qui donne 8 directions au maximum pour un gradient discret.

La détermination des points contours est ramenée dans un premier temps à la recherche de filtre linéaire permettant d'estimer le gradient en chaque point. Le filtrage linéaire utilisant un filtrage passe-haut précédé d'un léger filtrage passe-bas pour éliminer les bruits, ont été proposées [51][52].

Parmi les opérateurs les plus connus, on peut citer les opérateurs de gradients comme ceux de Sobel[53], Roberts[54] et Prewitt[55].

En plus de ces méthodes dérivatives de calcul du gradient, il existe le gradient morphologique qui est obtenu en effectuant la différence entre le dilaté et l'érodé de l'image I , soit en binaire, soit en niveaux de gris [56][57].

L'approche Laplacien

Les méthodes utilisant le gradient sont vulnérables contre les contours raides, dans ce cas il est possible d'utiliser la deuxième dérivée où un contour peut être détecté par un passage à zéro de la dérivée seconde. Dans une fonction bidimensionnelle (comme une image 2D), on utilise un opérateur invariant par rotation (car une fonction 2D n'a pas une dérivée seconde unique mais plutôt 4 dérivées partielles selon x^2, y^2, xy, yx) [58].

$$\nabla^2 f(x, y) = \frac{\partial^2 f(x, y)}{\partial x^2} + \frac{\partial^2 f(x, y)}{\partial y^2} \quad (3.5)$$

Le principe est de détecter l'emplacement d'un point de contour grâce au passage de zéro du Laplacien.

Etant donné que l'estimation de la dérivée seconde est très sensible au bruit, l'image doit être filtrée avant de calculer le Laplacien. Le Laplacien permet d'obtenir des contours fermés et d'un pixel d'épaisseur. Les contours peuvent ainsi être déterminés par la recherche du passage par zéro de la dérivée seconde également appelé « zero crossing » [56][59].

Le calcul du Laplacien a des avantages. Il est proche du mécanisme de la vision humaine et utilise un seul paramètre (le masque). Il n'utilise pas le seuil de significativité de l'amplitude. Parmi ses inconvénients, on peut citer : sa grande sensibilité au bruit et le fait qu'il n'ait pas d'information sur l'orientation du contour [60].

3.2.2.1.2 Méthodes analytiques :

Les méthodes dérivatives sont faciles à implémenter, rapides en termes de temps de calcul et donnent généralement de bons résultats sur des images non bruitées. Elles restent cependant sensibles aux petites variations non significatives des niveaux de gris (bruit) et produisent des contours discontinus qu'il faut ensuite fermer. Pour améliorer la qualité des méthodes dérivatives et pallier aux problèmes de précision et de localisation des contours, des opérateurs de dérivation avec filtrages optimaux ont été introduits. Les approches les plus intéressantes, et les plus utilisées sont ; le filtre de 'Canny', le filtre de 'Deriche' et le filtre de 'Shen et Castan', et qui sont des filtres monodimensionnels inspirés par les méthodes du traitement de signal.

Approche de Canny

Canny [61] a proposé en 1986 une étude théorique de la détection de contours dans laquelle il a formalisé trois critères que doit valider un détecteur de contour.

Trois critères ont été définis afin d'obtenir un filtre optimal pour la détection de contour :

- 1. Bonne détection : détecter un maximum de contours.
- 2. Bonne localisation : les points détectés doivent être les plus proches possibles du vrai contour.
- 3. Réponse unique : minimiser le nombre de contours détectés plusieurs fois.

A chaque critère est associée une formule mathématique. La maximisation de ces critères conduit à la résolution d'une équation différentielle dont la solution est le filtre qui permet la détection du contour. En fixant des conditions initiales, Canny a montré que la solution peut être approximée par la dérivée d'un filtre gaussien.

Approche de Deriche

Deriche [62] a repris le même problème de Canny en utilisant un filtre ayant une réponse impulsionnelle infinie. Il a pu donc être synthétisé de façon récursive particulièrement efficace. Une caractéristique importante du filtre de Deriche est qu'il peut être implémenté d'une façon récursive, ce qui permet de réduire le nombre d'opérations élevé qui requiert la convolution [63]. Ce filtre donne des résultats comparables ou meilleurs que le filtre de Canny.

Approche de Shen et Castan

Le filtre de Shen et Castan [64] est obtenu par optimisation d'un critère incluant la détection et la localisation. La solution obtenue est assez proche de celle de Canny, l'image est lissée et les contours sont détectés par un opérateur différentiel obtenu par dérivation d'un filtre de lissage de réponse impulsionnelle.

Ce filtre, puisque il est basé à l'origine pour optimiser une bonne détection et localisation seulement, donne une localisation très précise des contours, mais il est sensible aux bruits.

3.2.2.1.3 Méthodes déformables

Les modèles déformables, introduits par Kass [65] sont aussi connus sous les noms de

« snakes » ou « contours actifs ».

Ces contours actifs sont définies comme des courbes capables de se déformer et de se déplacer pour épouser la forme des objets constituant l'image [66].

L'intérêt principal des contours actifs est de détecter des objets dans une image en utilisant les techniques d'évolution de courbes. L'idée est de partir d'une courbe initiale, généralement un carré ou un cercle, et de la déformer jusqu'à obtenir le contour de l'objet.

Les contours actifs permettent de détecter des contours fermés mais restent sensibles, à l'instar des méthodes dérivatives, aux variations locales des niveaux de gris. La figure (4.15) illustre l'évolution de contour actif avec $\Gamma(\tau)$ est le contour initial qui peut être défini manuellement et v la vitesse d'évolution de la courbe.




FIGURE 3.11 – Evolution du contour actif $\Gamma(\tau)$ avec la vitesse v vers l'objet d'intérêt

Il existe d'autres approches d'extraction de contours qui font appel à d'autres modèles de l'image comme les approches surfaciques : L'image des intensités est considérée comme une surface. Dans ce cadre, la transition entre deux régions est modélisée par un modèle surfacique. Le contour est présent quand il y a une bonne corrélation entre le modèle surfacique et une zone de l'image [67].

Les détecteurs de contours présentés jusqu'ici ne donnent pas généralement des contours complets (des contours fermés entourant un objet), mais ils donnent des points ou des morceaux isolés de contours. Une étape de fermeture des contours sera donc généralement nécessaire avant de commencer la phase d'interprétation [68].

3.2.2.1.4 Limites de la segmentation par contour :

Les principales limites des méthodes de détection de contour sont les suivantes [69] :

- Les contours extraits selon les méthodes classiques souvent ne correspondent pas nécessairement à la limite des objets. Dans de nombreuses images de basse qualité, quelques-unes des méthodes produisent des faux contours.
- Les techniques de détection de contour dépendent de l'information contenue dans le voisinage local de l'image. Il n'y a pas d'information globale.
- Dans la plupart des cas, les stratégies de détection des contours ignorent l'organisation d'ordre supérieur qui peut être utilement présent dans l'image.
- Après l'extraction des points de contours, ces derniers sont reliés afin de déterminer les frontières. Le processus de fermeture des contours peut parfois conduire à des discontinuités et des lacunes dans l'image.
- Il est souvent difficile d'identifier et de classer les contours parasites.

3.2.3 Segmentation par l'approche «coopérative »

La segmentation par coopération régions-contours exploite les avantages de ces deux types de segmentation afin d'aboutir à un résultat de segmentation plus précis et plus fidèle que celui obtenu à l'aide d'une seule technique.

Globalement, une approche contour permet la localisation des contours non continus donc difficilement utilisables. En y joignant une approche région dont les caractéristiques sont l'obtention de zones fermées et homogènes, elle peut ainsi pallier les faiblesses de chacune des techniques : la faible précision du contour (approche région) et l'obtention de régions non fermées (approche contour). Il existe trois formes de coopération région-contour [70] :

1. *Coopération séquentielle* : L'une des techniques de segmentation (région ou contour) est réalisée en premier lieu : son résultat va être exploité par l'autre technique pour renforcer la définition des critères ou des paramètres de la segmentation ; L'intégration de

l'information provenant de la segmentation par contours dans une segmentation par régions est l'une des formes de coopération les plus courantes (Figure 4.15).




FIGURE 3.12 – Coopération séquentielle

2. *la coopération des résultats* : les deux types de segmentation seront réalisés indépendamment, la coopération concernera leurs résultats qui seront intégrés afin d'atteindre une meilleure segmentation.




FIGURE 3.13 – Coopération des résultats

3. *Coopération mutuelle* : Les deux types de segmentation coopéreront mutuellement au cours de leur processus d'exécution (Figure 3.13). La coopération permet de prendre des décisions plus sûres et plus fiables.

3.3 Seuillage

Le seuillage est une méthode de segmentation simple et très populaire pour le traitement des images numériques, Elle permet de répartir les pixels en classes en fonction de leurs




FIGURE 3.14 – Coopération mutuelle

niveaux de gris. Les classes sont alors délimitées par des seuils. Les seuils optimaux sont ceux qui séparent les objets entre eux ou différents objets du fond.

Le seuillage consiste à classer suivant le nombre de classes, les différents pixels d'une image, en se basant sur l'histogramme de niveaux de gris de l'image. En d'autres termes, la segmentation d'une image en N classes consiste à chercher $N - 1$ seuils.

Soit I_o l'image originale et I_s l'image segmentée, la classification de chaque pixel est définie par :

$$I_s(i, j) = k \text{ si } T_k \leq I_o(i, j) \leq T_{k+1} \text{ pour } k = 0, 1, \dots, N - 1$$

Où i, j sont les coordonnées du pixel, N est le nombre de classes et $T_1, \dots, T_{N-1}$ sont les différents seuils de segmentation.

- Si $N=2$ alors le pixel est étiqueté «fond», sinon le pixel est étiqueté «objet». Dans ce cas, on parle du seuillage tout court (bilevel hresholding) et l'image segmentée ainsi obtenue est appelée image binaire.
- Sinon, le nombre de seuils recherchés est supérieur à 1, on parle de multi-seuillage ou multi-level thresholding.

Ces méthodes peuvent être divisées, entre autre, en deux catégories. Les méthodes de seuillage global et les méthodes de seuillage local.




FIGURE 3.15 – Exemple de seuillage d’une image à deux classes à l’aide de l’histogramme

3.3.1 Seuillage global

La méthode de seuillage global est utilisée lorsque la distribution d’intensité entre les objets d’avant-plan et d’arrière-plan est très distincte. Lorsque les différences entre les objets d’avant-plan et d’arrière-plan sont très distinctes, une seule valeur de seuil peut simplement être utilisée pour distinguer les deux objets. Ainsi, dans ce type de seuillage, la valeur du seuil T dépend uniquement de la propriété du pixel et de la valeur de niveau de gris de l’image. Certaines méthodes de seuillage global les plus couramment utilisées sont la méthode Otsu, le seuillage basé sur l’entropie, etc.

L’algorithme d’Otsu est une technique de seuillage global populaire. De plus, il existe de nombreuses techniques de seuillage populaires telles que Kittler et Illingworth, Kapur, Tsai, Huang, Yen et al. [71].

Il existe deux méthodes de seuillage global :

Les méthodes paramétriques : Ces méthodes reposent sur l’hypothèse que les régions (classes) de l’image suivent des fonctions de densité de probabilité. Généralement, une combinaison Gaussienne est utilisée. La première étape consiste à estimer les paramètres des modèles, et la deuxième étape consiste à déterminer les seuils (intersection des modes).

Les méthodes non paramétriques : Ces méthodes permettent de trouver le seuil optimal de segmentation sans aucune estimation de paramètres. Généralement, ces méthodes sont basées sur l’optimisation de critères statistiques.

3.3.1.1 Méthodes paramétriques :

Ces méthodes supposent que l'histogramme $H(i)$ peut être approximé par une combinaison linéaire de fonctions de densité de probabilité (fdp) $f(i)$ dont le modèle est connu à priori tel que :

$$f(i) = \sum_{k=1}^K P_k H(i, \theta_k) \quad (3.6)$$

avec

$$P_k = \frac{h(i)}{N} \text{ sachant que } i \in C_i$$

Où P_k est la probabilité à priori de la classe C_k et qui peut être estimé par le nombre de pixels de la classe C_k sur le nombre total N de pixels et $H(i, \theta_k)$ est la fonction de densité de probabilité de la classe correspondant à la k ème distribution. Chaque distribution est caractérisée par des paramètres qu'on notera θ_k . Le problème de seuillage paramétrique consiste alors à estimer les paramètres (P_k, θ_k) de chaque distribution, en utilisant soit l'algorithme EM [72], soit en minimisant l'erreur totale suivante :

$$J(T) \cong J(\Theta) = \frac{1}{L} \sum_{i=0}^{L-1} [H(i) - f(i)]^2 \quad (3.7)$$

Souvent, les fonctions de densités de probabilité sont supposées suivre un modèle gaussien de moyenne μ_k et de variances σ_k tel que :

$$H(i, \theta_k) = \frac{1}{\sigma_k \sqrt{2\pi}} \exp \left[-\frac{(i - \mu_k)^2}{\sigma_k^2} \right] \quad (3.8)$$

P_k, μ_k et σ_k peuvent être estimés par :

$$P_k = \frac{1}{N} \sum_{i=t_{k-1}}^{t_k-1} h(i), \mu_k = \frac{1}{N} \sum_{i=t_{k-1}}^{t_k-1} ih(i), \sigma_k = \frac{1}{N} \sum_{i=t_{k-1}}^{t_k-1} (i - \mu_k)^2 h(i)$$

Le vecteur paramètre recherché est défini par : $\Theta = P_k, \mu_k, \sigma_k$ avec $k = 1, 2, \dots, K$.

La minimisation de la fonctionnelle $J(T)$ ou $J(\Theta)$ peut être résolue par l'algorithme d'estimation-maximisation [73].

Il existe d'autres algorithmes qui ont utilisé, ces méthodes comme : [74][75][76].

3.3.1.2 Méthodes non paramétriques :

3.3.1.2.1 Methode d'Otsu :

L'algorithme suppose que l'image contient deux classes de pixels suivant un histogramme bimodal (pixels de premier plan et pixels d'arrière-plan). La méthode d'Otsu implique l'itération à travers toutes les valeurs de seuil possibles et le calcul d'une mesure de propagation pour les niveaux de pixel de chaque côté du seuil, c'est-à-dire les pixels qui tombent soit au premier plan ou à l'arrière-plan. L'objectif est de trouver la valeur de seuil où la somme des écarts de premier plan et de fond est au minimum [77].

Dans cette méthode, le calcul des différents critères est basé sur la densité de probabilité des différents pixels de l'image, qui est obtenue en normalisant l'histogramme de l'image :

$$p_i = \frac{h(i)}{\sum_{j=0}^{L-1} h(j)} \quad (3.9)$$

avec

$$p_i \geq 0, \text{ et } \sum_{j=0}^{L-1} p_i = 1$$

où $h(i)$ est le nombre d'occurrences du pixel de niveau de gris $i \in [0 \dots L-1]$ et L le nombre total de niveaux de gris.

Dans le cas d'une binarisation, le seuil optimal t^* est celui qui maximise le ratio de la variance interclasse à la variance totale :

$$t^* = \arg \max_{0 \leq t_k \leq L-1} \frac{\sigma_B^2(t)}{\sigma_T^2} \quad (3.10)$$

où variance interclasse est définie par :

$$\sigma_B^2(t) = P_t(1 - P_t)(\mu_0 - \mu_1)^2 \quad (3.11)$$

et

$$\sigma_T^2 = \sum_{i=1}^{L-1} p_i(i - \mu_T)^2 \quad (3.12)$$

où μ_0 et μ_1 sont les niveau de gris moyen de chaque classe et μ_T est le niveau de gris moyen de l'image :

$$\mu_0 = \sum_{i=0}^t i \cdot \frac{p_i}{P_t}, \quad \mu_1 = \sum_{i=t+1}^{L-1} i \cdot \frac{p_i}{1 - P_t}, \quad \mu_T = \mu_0 + \mu_1$$

P_t et $1 - P_t$ représentent les probabilités à priori de chaque classe tel que :

$$P_t = \sum_{i=0}^t p_i, \quad 1 - P_t = \sum_{i=t+1}^{L-1} p_i$$

Dans le cas du multiseuillage, la méthode d'Otsu peut être étendue au calcul d'un ensemble de seuils $t_* = (t_1, t_2, \dots, t_{K-1})$ en maximisant la variance interclasses.

$$T^* = \text{Arg max}_{0 \leq t_k \leq L-1} J(T) \quad (3.13)$$

où

$$J(T) = \sigma_B^2 = \sum_{j=1}^J P_j(\mu_j - \mu_G)^2 \quad (3.14)$$

avec P_j et μ_j les probabilités et la moyennes respectives de la classe C_j tels que :

$$P_j = \sum_{i \in C_j} p_i \quad \text{et} \quad \mu_j = \frac{1}{P_j} \sum_{i \in C_j} ip_i,$$

et μ_G la moyenne globale

$$\mu_G = \sum_{i=0}^{L-1} ip_i$$

3.3.1.2.2 Seuillage entropique :

Une autre méthode de seuillage global basée sur la théorie de l'entropie cette fois ci, est proposée par Kapur [78]. Elle consiste en la maximisation de l'entropie des classes, ce qui peut être interprété comme une mesure de compacité de classes et ainsi de séparabilité des classes. Le seuil optimal est vu comme celui qui maximise la somme des entropies des deux classes. Les densités de probabilité des deux classes (A et B) sont définies par :

$$\begin{aligned} \text{Classe A} : & \frac{p_1}{P_t}, \frac{p_2}{P_t}, \dots, \frac{p_t}{P_t} \\ \text{Classe B} : & \frac{p_{t+1}}{1 - P_t}, \frac{p_{t+2}}{1 - P_t}, \dots, \frac{p_L}{1 - P_t} \end{aligned}$$

où L est le nombre total de niveaux de gris et P_t la probabilité cumulée définie par :

$$P_t = \sum_{i=0}^t p_i$$

Les entropies des deux classes A et B sont définies par :

$$H_A(t) = - \sum_{i=1}^t \frac{p_i}{P_t} \log_2 \frac{p_i}{P_t} \quad (3.15)$$

$$H_B(t) = - \sum_{i=1}^t \frac{p_i}{1 - P_t} \log_2 \frac{p_i}{1 - P_t} \quad (3.16)$$

L'entropie totale est la suivante :

$$H_T(t) = H_A(t) + H_B(t) \quad (3.17)$$

Le premier problème avec cette méthode, souligné par [79], est que l'entropie de Shannon n'est pas définie pour les densités de probabilité incluant des probabilités nulles. [79] ont alors proposé une nouvelle définition de l'entropie basée sur un gain exponentiel d'information :

$$H_T(t) = - \sum_{i=1}^t \frac{p_i}{P_t} e^{1-\frac{p_i}{P_t}} - \sum_{i=1}^t \frac{p_i}{1-P_t} e^{1-\frac{p_i}{1-P_t}} \quad (3.18)$$

Le seuil optimal t^* est alors défini comme étant le niveau de gris qui maximise les deux entropies, c'est-à-dire que :

$$t^* = \underset{1 \leq t_k \leq L}{\text{Arg max}} H_T(t) \quad (3.19)$$

Cette méthode peut être également étendue au calcul de plusieurs seuils $T = t_1, t_2, \dots, t_{K-1}$, il s'agira alors de maximiser le critère suivant :

$$J(T) = \sum_{k=1}^K H_k \quad (3.20)$$

avec

$$H_k = - \sum_{i=t_{k-1}}^{t_k-1} \frac{p_i}{P_k} e^{1-\frac{p_i}{P_k}} \text{ et } P_k = \sum_{i=t_{k-1}}^{t_k-1} p_i$$

3.3.1.2.3 Méthode K-means :

L'algorithme K-means a été développé par J. MacQueen [80], c'est un algorithme itératif qui minimise la somme des distances entre chaque objet et le centroïde de sa classe. La position initiale des centroïdes conditionne le résultat final. K-means change les objets de la classe jusqu'à ce que la somme ne puisse plus diminuer. Le résultat est un ensemble de classes compacts et clairement séparés, sous réserve d'avoir choisi la bonne valeur K du nombre de classes. L'idée principale est de définir K centroïdes, un pour chaque classe C_k $1 \leq k \leq K$. Chaque classe C_k est ainsi caractérisée par son centre noté μ_k et le nombre

d'éléments N_k .

L'algorithme K-means dans sa formulation originale cherche à minimiser une fonction de coût global définie par :

$$J = \sum_{k=1}^K \sum_{(i,j) \in C_k} (I(i,j) - \mu_k)^2 \quad (3.21)$$

où $I(i,j)$ représente le niveau de gris du pixel de coordonnées (i,j) .

Il se déroule selon les étapes suivantes :

1. Initialisation de chaque centre μ_k .
2. Pour chaque pixel (i,j) , calculer la distance $d(I(i,j), \mu_k)$ aux différents centres des classes, et affecter à la classe la plus proche $C_k = \arg \min_k d(I(i,j), \mu_k)$ avec $d(I(i,j), \mu_k) = |I(i,j) - \mu_k|$.
3. Mise à jour de nombre de pixels et des centres $\mu_k = \frac{\sum_{(i,j) \in C_k} I(i,j)}{N_k}$.
4. Arrêt si $N_k = N_{k+1} \quad \forall (i,j) \in C_k$, sinon retour à l'étape 2.

Le principal inconvénient de cette méthode est que la classification finale dépend du choix de la partition initiale. Le minimum global n'est pas nécessairement pris, on est seulement certain d'obtenir la meilleure partition à partir de la partition de départ choisie [81]. De nombreuses variantes peuvent être rencontrées. Par exemple, au lieu de calculer le centre des classes, après avoir affecté tous les pixels, les centres de gravité peuvent être calculés immédiatement après chaque affectation. La méthode des K-means a été généralisée sous l'appellation de la "méthode des nuées dynamiques" [82].

3.3.2 Seuillage local

Dans ces méthodes de seuillage, on calcule une valeur de seuil pour chaque pixel sur la base d'informations contenues dans son voisinage.

Dans ces méthodes de seuillage, la classification d'un pixel dépend non seulement du son niveau de gris mais aussi de ses informations locales, c'est-à-dire des niveaux des gris des pixels voisins. On définit alors un seuil pour chaque pixel selon sa position.

Les méthodes de seuillage dynamique sont basées sur le calcul de seuil, qui peut se faire en considérant une fenêtre de voisinage de taille $W \times W$ centrée autour d'un pixel qu'on fera glisser tout au long de l'image.

Le seuil dépendra alors du pixel et de l'information extraite à partir de son voisinage.

Parmi les méthodes de seuillage local existantes, celle de Niblack [83] est rapide, facile à implémenter et à appliquer. Elle consiste à faire varier la valeur du seuil sur l'image. Ainsi le seuil est calculé en fonction de la somme de la moyenne locale et de la variance locale pondérée par un paramètre ajustable. Le voisinage considéré doit être suffisamment petit pour la préservation des détails de l'image.

Sauvola et al[84] ont proposé une modification de la méthode de Niblack, pour donner plus de performance à la méthode en présence d'images avec un fond légèrement bruité ou contenant trop de variations et une illumination inégale. Cette modification fait apparaître dans le calcul du seuil la portée dynamique de l'écart type.

La technique de seuillage local par niveau logique proposée par [85], est basée sur la comparaison du niveau de gris d'un pixel avec les niveaux de gris moyen de quelques pixels voisins.

Les méthodes de seuillage local sont confrontées au choix de la taille de la fenêtre de voisinage. Celle-ci doit être suffisamment petite pour préserver les détails locaux et suffisamment larges pour supprimer le bruit.

Il existe également d'autres méthodes de segmentation qui n'appartiennent pas aux catégories citées précédemment et qui utilisent des formalismes différents. A titre d'exemple, on peut citer la méthode des contours actifs basée région [80], les réseaux de neurones comme les cartes organisatrices de Kohonen [86], [87] connu sous le nom de SOM (Self Organising Map), la morphologie mathématique représentée par l'algorithme de lignes de partage des eaux [88][89] ... etc.

3.4 Conclusion :

La segmentation est une étape primordiale en traitement d'image et du fait qu'il n'existe pas de méthode unique de segmentation, il est difficile de définir, de manière absolue, une « bonne » segmentation. La segmentation n'est pas une fin en soi, sa qualité est fonction des résultats obtenus par les traitements situés en aval qui utilisent les primitives extraites.

Dans ce chapitre, nous avons indiqué quelques notions sur la segmentation d'images, nous avons étudié les principales approches classiques de segmentation en les classant en trois catégories : les approches région qui contient un grand nombre de méthodes dont la plus part d'entre elles se basent sur le seuillage et les approches contour, et nous avons donné un aperçu sur le principe de coopération entre ces deux approches.

En découle que le domaine de la segmentation est tellement riche et diversifié qu'il est difficile de donner une étude complète.

Chapitre 4

Approches développées

4.1 Introduction :

La segmentation des images est toujours un problème non résolu. En réalité, avec les avancées technologiques des capteurs, un grand nombre d'images à haute résolution spatiale et spectrale sont générées chaque jour.

Les méthodes de segmentation des images de satellite permettent une analyse de données en regroupant les pixels les plus semblables entre eux en différentes classes. Les méthodes les plus classiques n'introduisent que des informations d'ordre spectral. Ces méthodes posent le plus souvent des problèmes de confusion entre les différentes classes. Cela est dû à l'insuffisance de la réponse spectrale à caractériser un objet présent dans les images manipulées.

Par conséquent, il est nécessaire d'élaborer de nouvelles méthodes de segmentation qui permettent de détecter les régions d'intérêt dans les images multispectrales. Ce chapitre présente des méthodes pour la segmentation des images de haute résolution spatiale, la première s'étend de la théorie de l'optimisation en permettant à plusieurs objectifs de conception d'optimiser simultanément et la deuxième est basée sur le concept quantique.

4.2 Approche multicritère :

L'optimisation multiobjective s'étend de la théorie de l'optimisation en permettant à plusieurs objectifs de conception d'optimiser simultanément. Un problème d'optimisation multiobjective est résolu d'une manière similaire au simple problème objectif classique. L'objectif est de trouver un ensemble de valeurs pour les variables de conception qui optimisent simultanément plusieurs fonctions objectives (ou coûts). En général, la solution obtenue par l'optimisation séparée de chaque objectif (optimisation objective simple) ne représente pas une solution possible pour le problème multiobjectif.

L'approche proposée dans [90] est justifiée par la simple raison que dans presque tous les cas, le processus de segmentation basé sur l'optimisation d'un seul critère ne fonctionne pas très bien pour de nombreuses images. Souvent, la valeur optimale du seuil pour chaque critère ne produit pas de segmentation d'image satisfaisante. Ici, nous proposons des seuils

optimaux qui permettent d'optimiser un ensemble de critères.

Notre fonction objective est basée sur trois critères :

- Le critère de la variance intra-classe.
- Le critère de la probabilité globale.
- Le critère de l'entropie.

Nous présentons les différents critères qui ont été repris par notre méthode.

4.2.1 Critère de la variance intra-classe

Le seuillage a tablé sur la variance intra-classe qui tend à classer une image comme l'objet et le fond de tailles similaires. Afin de surmonter cet inconvénient, une fonction objective était dérivée du critère classique de variance intra-classe.

Certaines connaissances à priori sur les caractéristiques de la segmentation résultante, telles que l'uniformité ou l'homogénéité des régions et la simplicité de l'intérieur des régions.

La modification proposée consiste dans l'intégration des critères sur les propriétés de segmentation idéale. L'expression du critère la variance intra-classe, pour une image I , s'écrit :

$$MVar(I) = \alpha \sum_{i=1}^{NR} \frac{Var(i)^2}{\beta_i} + \gamma_i \quad (4.1)$$

Avec

$$\alpha = \frac{\sqrt{NR}}{10000XM}, \beta_i = \frac{1}{1+Log(N_i)}, \gamma_i = \left(\frac{R(N_i)}{N_i}\right)^2$$

Où

- NR est le nombre des régions.
- N_i indique le nombre de pixels dans la région i .
- $R(N_i)$ est le nombre de régions dont le cardinal est égal à N_i .

Et $\text{Var}(i)$ définit par :

$$\text{Var}(R) = \sum_{i=1}^{NR} P_i (m_i - m_G)^2 \quad (4.2)$$

Avec

$$m_i = \frac{1}{P_i} \sum_{i \in C_i} i p_i, m_G = \sum_{i=0}^{L-1} i P_i, P_i = \sum_{i \in C_i} p_i, p_i = \frac{h(i)}{\sum_{j=0}^{L-1} h(j)}$$

Où

- m_i est l'intensité moyenne des pixels dans la classe i .
- m_G est la moyenne global.
- P_i est la probabilité de la classe i .
- p_i est la fonction de densité de probabilité de différents pixels de l'image.
- $h(i)$ est le nombre d'occurrences du pixel de niveau de gris $i \in [0, L-1]$ et L le nombre total de niveaux de gris.

4.2.2 Critère de la probabilité globale

Après la configuration de l'histogramme correctement à l'aide de la fonction de densité de probabilité gaussienne. Le seuil optimal est déterminé en minimisant la probabilité globale d'erreur. Pour deux probabilités gaussiennes successives de fonctions de densité, la fonction a été donnée par :

$$e(T_i) = P_i \int_{-\infty}^{T_i} p_i(x) dx + P_{i+1} \int_{T_i}^{+\infty} p_{i+1}(x) dx$$

$i = 1, 2, \dots, d-1$ par rapport au seuil T_i ,

Donc, la probabilité globale à minimiser est défini par :

$$E(T) = \sum_{i=1}^{d-1} e(T_i) \quad (4.3)$$

Où T est le vecteur de seuils : $0 < T_1 < T_2 < \dots < T_d - 1 < 255$.

4.2.3 Critère de l'entropie

Les entropies des deux classes A et B sont définies par [81] :

$$H_A(t) = - \sum_{i=1}^t \frac{p_i}{P_t} \log_2 \left(\frac{p_i}{P_t} \right)$$

$$H_B(t) = - \sum_{i=t+1}^L \frac{p_i}{1 - P_t} \log_2 \left(\frac{p_i}{1 - P_t} \right)$$

L'entropie totale est :

$$H_T(t) = H_A(t) + H_B(t)$$

Le premier problème avec cette méthode, souligné par [79] , est que l'entropie de Shannon n'est pas définie pour les densités de probabilité incluant des probabilités nulles. MacQueen[79] est proposé une nouvelle définition de l'entropie basée sur un gain exponentiel d'information :

$$H_T(t) = - \sum_{i=1}^t \frac{p_i}{P_t} e^{(1 - \frac{p_i}{P_t})} - \sum_{i=t+1}^L \frac{p_i}{1 - P_t} e^{(1 - \frac{p_i}{1 - P_t})} \quad (4.4)$$

4.2.4 Fonction multiobjective :

La fonction multiobjective appliquée aux images à deux seuils (comme les images médicales) par [90] est définie comme suit :

$$MOBJ1(T) = w_1 MVar(R(T)) + w_2 E(T) \quad (4.5)$$

Où T est le vecteur des seuils : $0 < T_1 < T_2 < \dots < T_{d-1} < 255$, $w_1 = 1 - w_2$ et $w_2 = \frac{\sum_{i=1}^d \sigma_i^2}{\sigma_{Histogram}^2}$

Avec d est le nombre de classe, σ_i est l'écart type de classe i et $\sigma_{Histogram}$ est l'écart type de l'histogramme.

Cette fonction a certainement été couronnée de succès mais elle a montré ses limites. Pour cette raison, nous avons pensé à introduire un autre facteur comme l'entropie à la fonction (Équation 4.5). Notre fonction multiobjective est définie comme suit :

$$MOBJ2(T) = w_1 MVar(R(T)) + w_2 E(T) + w_3 H_T(T) \quad (4.6)$$

Où $w_1 = 1 - w_2 - w_3$, $w_2 = \frac{\sum_{i=1}^d \sigma_i^2}{\sigma_{Histogram}^2}$ et $w_3 = \frac{m_G}{\sum_{j=1}^d j}$

Les paramètres de pondération (w_1, w_2 et w_3) permettent de toucher la limite du domaine faisable. Cette opération a été utilisée lorsque l'objectif de la segmentation est d'extraire la cible de l'image originale.

4.3 Approche quantique :

Dans cette approche, nous intégrons l'image satellite comme une image RGB, où chaque composante peut représenter n'importe quelle bande d'image.

4.3.1 Modèle pour la Particule :

Dans une boîte bidimensionnelle, on considère un modèle de la particule confinée à un plan rectangulaire, de longueur L_x dans la direction X et de largeur L_y dans la direction Y .

L'énergie potentielle est nulle partout dans ce plan, et infinie à ses parois et au-delà, ce qui présente à l'équation suivante :




FIGURE 4.1 – Modèle de la Particule.

$$V(x, y) = \begin{cases} 1 & \text{pour } 0 < x < L_x \text{ et } 0 < y < L_y \\ \infty & \text{ailleurs} \end{cases} \quad (4.7)$$

La fonction d'onde est maintenant une fonction qui dépend des deux variables x et y , et l'équation de Schrödinger pour le système est donc :

$$\frac{-\hbar^2}{2m} \left(\frac{\partial^2 \Psi}{\partial x^2} + \frac{\partial^2 \Psi}{\partial y^2} \right) = E \Psi(x, y) \quad (4.8)$$

Où :

- $\hbar$ est la constant de Planck réduite, $\hbar^2 = \frac{h}{2\pi}$;
- m est la masse de la particule ;
- E est la valeur propre de l'énergie.

Cette équation est résolue par la technique de séparation des variables $\Psi(x, y) = \Psi(x)\Psi(y)$. Chacune de ces deux variables est respectée de la même qu'une particule dans une boîte unidimensionnelle, de sorte que nous pouvons immédiatement noter les solutions suivantes :

$$\Psi_{n_x}(x) = \sqrt{\frac{2}{L_x}} \sin\left(\frac{n_x \pi x}{L_x}\right) \quad (4.9)$$

$$\Psi_{n_y}(y) = \sqrt{\frac{2}{L_y}} \sin\left(\frac{n_y \pi y}{L_y}\right) \quad (4.10)$$

La densité de probabilité c'est la propriété d'une particule dans une boîte qui doit être examinée et selon l'interprétation cette densité est donnée par : $|\Psi|^2$.

4.4 Critères d'évaluation :

Afin de mettre en œuvre les performances des approches développées et de comparer avec des méthodes classiques, l'utilisation des critères d'évaluation s'avère nécessaire. Plusieurs critères d'évaluation existent dans la littérature.

La multiplicité des méthodes de segmentation d'images nécessite d'avoir un critère d'évaluation fiable qui permettra de mesurer le degré de confiance dans le résultat fourni par une méthode de segmentation.

Toute étude dédiée à l'évaluation de la segmentation d'images se manifeste par le développement d'un ensemble de techniques permettant de mesurer la performance de l'algorithme de segmentation. Les chercheurs ont ressenti le besoin d'avoir un moyen pour mesurer la qualité de la segmentation. Cette mesure permettant de l'évaluer, et de comparer les différentes méthodes qui existent.

L'évaluation par Barra [91] est cruciale, car elle permet des suivantes :

- Comparer les résultats d'une méthode de segmentation par rapport à une autre ;
- Choisir l'algorithme le plus adéquat à son application, et régler ses paramètres, en fonction du problème à résoudre.

L'évaluation de l'efficacité d'une nouvelle méthode de segmentation est illustrée par la présentation de quelques résultats de segmentation, ce qui n'autorise que des conclusions subjectives et qualitatives sur les performances de cette méthode.

4.4.1 Différents types d'erreurs de segmentation :

Les erreurs qui peuvent être faites lors d'une segmentation sont de trois types : les erreurs de sur-segmentation, les erreurs de sous-segmentation et les erreurs de localisation [91] :

Erreur de sur-segmentation : Les algorithmes de segmentation peuvent ne pas affecter des pixels à un contour ou à une région correctement.

Erreur de sous-segmentation : Lorsque la différence de niveau de gris (ou de couleur) entre deux régions voisines n'est pas très efficace, un certain nombre d'algorithmes de segmentation ne détectent pas le contour ou la région. Ainsi, certains pixels appartenant à un contour ne seront pas pris, on parle alors de sous-segmentation.

Erreur de localisation : Quand la segmentation par contour, les pixels contours doivent être placés dans l'une ou l'autre des régions. Deux méthodes différentes de segmentation peuvent parfaitement localiser la limite désirée dans une image, mais pendant que l'une dessine le contour du côté sombre, l'autre la place du côté plus clair. Les images contours obtenues sont évidemment différentes et les pixels contour sont considérés comme mal classés, puisqu'ils ne sont pas à leurs emplacements réels et donnent des erreurs de localisation.

4.4.2 Classification des Algorithmes d'évaluation :

Certaines techniques d'évaluation mesurent un indice de «bonne qualité » de la segmentation. Lorsque cet indice est élevé, on considère que la segmentation est bonne. D'autres, mesurent la « différence » entre l'image segmentée et l'image de référence.

De nombreux critères d'évaluation d'un résultat de segmentation d'images ont été proposés. Chabrier [93] a divisé ces critères d'évaluation en deux catégories principales : critères d'évaluation supervisée et critères d'évaluation non supervisée. L'objectif principal d'un critère d'évaluation est d'être capable de comparer de différents résultats de segmentation afin de trouver la meilleure segmentation [94].

4.5 Critères d'évaluation supervisée :

Les résultats de segmentation sont évalués en considérant des connaissances a priori. Ces connaissances peuvent être modélisées par une segmentation de référence qu'on appelle une vérité terrain [95] ou par des connaissances sur les objets à identifier. Celle-ci peut être établie, sur une image naturelle, par un (ou des) opérateur(s) humain(s) expert(s) du domaine d'application, à l'aide de logiciels de dessin. Un cas plus confortable est celui des images synthétiques, dont la vérité terrain est rigoureusement accessible.

On rappelle les différentes approches selon que l'on soit confronté à l'évaluation d'une segmentation.

4.5.1 Évaluation avec une vérité terrain synthétique :

Dans le cas d'images synthétiques, L'évaluation est réalisée en mesurant la similarité entre le résultat obtenu par un algorithme et cette référence. L'évaluation peut être automatisée grâce à l'utilisation de cette métrique de similarité ce qui permet d'utiliser une base d'images très conséquente pour l'évaluation.

A l'inverse, un tracé expert est subjectif et la confiance que l'on peut accorder doit être connue ou estimée. La figure (4.2) montre, à l'aide d'un exemple, comment procéder lors d'une évaluation supervisée [96] .

L'inconvénient majeur de cette approche est que les images ne sont pas complètement représentatives de celles à traiter en mode opérationnel. Il est certes possible d'essayer de reproduire les conditions d'acquisition, le bruit du capteur et autres artefacts [97].

4.5.2 Évaluation avec une vérité terrain réalisée par un expert :

Cette approche d'évaluation a été très largement utilisée dans les dernières décennies pour justifier de la qualité d'un nouvel algorithme. Une incertitude existe sur les informations mises à disposition telles qu'un tracé réalisé par un expert. Un exemple de l'évaluation




FIGURE 4.2 – Evaluation supervisée avec vérité de terrain

avec une vérité de terrain réalisé par un expert est illustré dans la figure (Figure 4.3).

Une autre solution consiste à demander à des experts de générer manuellement le résultat optimal ou escompté du traitement (quand c'est possible). C'est une démarche couramment utilisée en détection d'objets dans une image par exemple. En général, on essaie de fusionner les vérités terrain générées par différents experts afin d'obtenir une référence représentative. Afin d'évaluer la qualité du résultat généré par un algorithme, une mesure de similarité avec la référence experte est utilisée [98] .

Un des inconvénients de cette approche est le coût de génération de la référence. La fusion des vérités terrain provenant de différents experts est aussi une tâche délicate, notamment concernant la gestion des informations complémentaires. En effet, si l'on observe les résultats




FIGURE 4.3 – Evaluation supervisée avec vérité de terrain experte

générés par les experts, le niveau de précision des résultats de segmentation est assez disparate. Ceci montre qu'il faut spécifier de façon très précise la tâche demandée aux experts[98] .

4.5.3 Evaluation de la segmentation en contours :

Des méthodes qui calculent la différence entre, la position réelle du contour, et la position du contour sur l'image segmentée ont été définies, nous mentionnons quelques-uns dans ce qui suit.

4.5.3.1 Critères de Pratt :

Pratt et al [99] ont proposé une mesure empirique de comparaison entre une carte de contours à évaluer (I_F) et une carte de contours de référence (I_{ref}), et est basée sur la position du pixel mal segmenté, et calculée par :

$$F(I_{ref}, I_F) = \frac{1}{\max(card(I_{ref}), card(I_F))} \sum_{i=1}^{card(I_F)} \frac{1}{1 + \alpha d^2(i)} \quad (4.11)$$

Où

- $d(i)$ correspond à la distance entre le pixel contour i dans la carte I_F et le plus proche pixel contour dans la référence I_{ref} ;
- α est une constante positive permettant de conserver la mesure de Pratt et respecter $0 \leq F \leq 1$;
- $card(I_F)$ correspond au nombre de pixels de contours sur l'image évaluer (image segmentée)
- $card(I_{ref})$ est le nombre de pixels de contours sur l'image de référence.

Cette mesure est l'une des plus utilisée, bien qu'elle n'ait pas de justification théorique, et la normalisation est effectuée de façon à avoir $0 \leq F \leq 1$, et $F(I_{ref}, I_F) = 1$ uniquement dans le cas où $I_{ref} = I_F$.

Certains inconvénients, liés à l'utilisation de cette mesure, elle n'est pas symétrique, elle est sensible aux erreurs de sur-détection et de localisation, mais n'est pas sensible aux erreurs de sous-détection et elle n'est pas sensible à la forme des zones erronées.

Straters et Gerbrands ont proposé une version modifiée de cette mesure [92].

$$P_c = \begin{cases} \frac{1}{N_c} \sum_{s=1}^N \frac{1}{1 + \alpha d^2(s)} & \text{si } N_c > 0 \\ 1 & \text{si } N_c = 1 \end{cases} \quad (4.12)$$

- Il va remplacer s par i dans l'équation
- N_c est le nombre de pixels sous-segmentés.

4.5.3.2 Critères de Fram et Deutsch :

Fram et Deutsch proposent deux critères P_1 et P_2 , qui servent à évaluer l'extraction d'un seul contour, dont on connaît la position exacte. Les calculs se font sur une zone de

contour notée Z . Un contour est optimal, s'il a un pixel d'épaisseur [100].

$$P_1 = \frac{N_i}{N_i + N_b + N_e} \quad (4.13)$$

$$P_2 = \frac{N_i}{N_l - N_2} \quad (4.14)$$

Où

- N_l le nombre de lignes de Z ;
- N_i le nombre de pixels de contour de Z détectés dans l'image résultat (un seul est correct par ligne) ;
- N_e le nombre de pixels détectés en dehors de Z ;
- N_b le nombre de fausses détections dans Z (cas de 2 pixels par ligne) ;
- N_2 le nombre de fausses détections dans Z (cas de 2 pixels par ligne) ;

Avec P_1 mesure la robustesse au bruit et P_2 vaut 1 s'il n'y a pas de lacune dans Z .

4.5.3.3 Critères de Peli et Malah :

Pour évaluer un contour, Peli et Malah [101] utilisent deux critères statistiques, l'un signifie la moyenne de l'erreur et l'autre signifie la variance de l'erreur de détection, ils sont les suivants :

$$PEL1(I_F, I_{Ref}) = \frac{1}{card(I_F)} \sum_{k=1}^{card(I_F)} d(I_F^{Cont}(k), I_{Ref}^{Cont}) \quad (4.15)$$

$$PEL2(I_F, I_{Ref}) = \frac{1}{card(I_F)} \sum_{k=1}^{card(I_F)} d^2(I_F^{Cont}(k), I_{Ref}^{Cont}) \quad (4.16)$$

La qualité de la validation est énormément dépendante de celle de la carte de contours de référence.

4.5.4 Evaluation de segmentation en régions :

Il y a moins de critères d'évaluation d'un résultat de segmentation en régions que ceux de détection de contours.

Un certain nombre de méthodes d'évaluation de la segmentation par région ont été proposés, selon que l'on dispose ou pas d'une vérité-terrain, nous signalons certains dans ce qui suit.

4.5.4.1 Critère de Vinet :

Critère de Vinet [102] consiste à mesurer la dissimilarité entre deux résultats de segmentation. Il permet de mesurer le pourcentage des pixels mal segmentés et à rechercher les couples des régions (R_i, R_j) ayant un recouvrement maximal telle que R_i appartient à la segmentation résultat I_{seg} et R_j à la segmentation de référence I_{ref} . Pour cela une matrice de recouvrement $T(I_{seg}, I_{ref})$ est construite tel que chaque élément $t_{ij} = \text{card}(R_i \cap R_j)$, $i = 1 \dots C_{seg}$ et $j = 1 \dots C_{ref}$ mesure le taux de recouvrement entre deux classes R_i, R_j . Il s'agit alors de rechercher d'une manière récursive les couples de régions (R_i, R_j) ayant un recouvrement maximal. Ce critère est défini comme suit :

$$Vinet(I_{seg}, I_{ref}) = 1 - \frac{1}{A} \sum_{k=1}^K \text{card}(R_i, R_j) \quad (4.17)$$

Avec

- K est le nombre de couple de classes qui maximisent $\text{card}(R_i \cap R_j)$;
- A est le nombre de pixel dans le résultat de la segmentation.

Ce critère est facile à appliquer et appartient à l'intervalle $[0, 1]$ mais il ne prend pas en compte toute l'information. Plus la valeur de Vinet est petite, meilleure est la segmentation.

4.5.4.2 Critère de Yasnoff :

Critère de YASNOFF et al. [103] consiste à compter le nombre de pixels mal segmentés tout en tenant compte de leur position, il est insuffisant pour mesurer la performance d'un algorithme de segmentation. Il est basé sur le calcul de la distance entre un pixel mal

segmenté et la région à laquelle il appartient dans la référence est définie comme suit :

$$C_Y = \frac{100}{N} \sqrt{\sum_{p_m T} d^2(p_m, p_{pr})} \quad (4.18)$$

Où

- N représente le nombre total de pixels dans l'image ;
- p_T le nombre total de pixels mal segmentés ;
- d la distance entre le pixel mal classé p_m et le pixel p_{pr} le plus proche de la région à laquelle il appartient dans l'image de référence.

Plus C_Y est petit, plus la segmentation est meilleure.

4.5.4.3 Critère de Martin :

Martin [104] , définit pour évaluer la cohérence entre deux segmentations d'une même image, une mesure qui peut être utilisée pour comparer deux segmentations l'une de référence, l'autre obtenue par un algorithme.

Elle est basée sur deux erreurs calculées en chaque pixel : une erreur de V par rapport à R et une erreur de R par rapport à V . Si le pixel p appartient à la région V_j dans la vérité-terrain et à la région R_i dans l'image résultat, ces erreurs valent :

$$E(p) = \frac{\text{card}(V_j \Delta R_i)}{\text{card}(V_j)}$$

et $E'(p) = \frac{\text{card}(R_i \Delta V_j)}{\text{card}(R_i)}$ (4.19)

Où

- l'opération de différence $V \Delta R$ est définie par : $V \Delta R = \{p/p \in V, p \notin R\}$;
- $E(p)$ vaut 0 si V_j est un sous-ensemble de R_i et vaut 1 si l'intersection des deux régions est réduite au pixel p .

La dissimilarité entre segmentation résultat et segmentation de référence se mesure alors par l'erreur locale de cohérence.

$$LCE(R, V) = \frac{1}{n} \sum_p \min\{E(p), E'(p)\} \quad (4.20)$$

Ou par l'erreur globale de cohérence

$$GCE(R, V) = \frac{1}{n} \min\left\{\sum_p E(p), \sum_p E'(p)\right\} \quad (4.21)$$

Avec n désigne le nombre total de pixels.

LCE et GCE sont définies de telle sorte que lorsque nous comparons deux segmentations, plus les valeurs d'erreur sont faibles, voire nulles, plus les segmentations sont presque identiques.

4.6 Critères d'évaluation non supervisée :

Contrairement aux approches d'évaluation de segmentation d'images avec segmentation de référence, les critères d'évaluation non supervisée mesurent la performance d'un algorithme de segmentation sans avoir moyen à une image de vérité terrain. Le principe des critères non supervisés est de quantifier la qualité du résultat d'un traitement d'images à partir d'un calcul statistique. Seule l'image originale peut être utilisée pour effectuer ce calcul.

Les différents algorithmes d'évaluation sont caractérisés simplement par le calcul des mesures définissant la segmentation idéale basé sur l'image segmentée sans connaissance de la vraie segmentation. Ils fournissent une évaluation de la qualité d'une segmentation en se basant sur des statistiques calculées sur les régions comme la variation de couleur à l'intérieur des régions, de contraste entre les régions et de taille de régions.

Plusieurs méthodes d'évaluation non supervisées ont été proposées. Elles peuvent être classées en méthodes analytiques et méthodes évaluant un critère de qualité. Nous allons

dans ce qui suit, en citer quelques-unes.

4.6.1 Évaluation analytique :

Les critères d'évaluation analytiques quantifient la performance des algorithmes de segmentation en analysant leurs principes ainsi que leurs propriétés (besoins, utilité, complexité, convergence, stabilité, etc...).

L'utilisation de critères analytiques pour évaluer des algorithmes de segmentation, permet de traiter l'influence ou du biais qui pourrait être causé par l'implémentation. Des critères analytiques ont été proposés entre autre par Liedtke [105] , Cho [106] et Voisine [107] .

Cependant, on ne dispose que de peu de connaissances théoriques générales dans le domaine de la segmentation d'images. C'est pourquoi, peu de propriétés peuvent être exploitées pour ces études analytiques limitant alors grandement leurs champs d'application.

4.6.2 Évaluation de critères de qualité :

Les méthodes présentées dans cette section reposent sur des critères de qualité calculés à partir d'images segmentées. La plupart de ces critères de qualité sont établis en accord avec l'intuition humaine sur les conditions à remplir par une segmentation pour qu'elle soit considérée comme bonne.

Il existe deux approches en segmentation : la segmentation en régions et la détection de contours. Les procédés d'évaluation étant différents pour ces deux catégories de segmentation, ils seront présentés séparément.

Dans ce qui suit, nous allons rappeler les critères de qualité les plus répandues.

4.6.2.1 Évaluation de la segmentation en contours :

L'évaluation non supervisée de segmentation en contours est confrontée à un problème de discernement entre un vrai contour (frontière entre deux régions) et un contour intra-régions [108] . La conséquence directe de ce problème est que très peu d'évaluation non supervisée

en contour ont été menées, contrairement au cas de la segmentation supervisée.

4.6.2.1.1 Critère de Kitchen et Rosenfeld :

Kitchen et Rosenfeld [109] ont proposé un critère d'évaluation de cartes de frontières fondée sur la cohérence locale des frontières. Elle utilise deux critères de caractérisation des contours, qui sont la continuité et la minceur. Les contours sont supposés être générés par un détecteur de contour, de type gradient, suivi d'un seuillage, et la direction du gradient est supposée connue en chaque point. La carte contour est évaluée par un score, qui est la moyenne des scores locaux, calculés en chaque point contour de l'image, en faisant une analyse sur un voisinage 3×3 . Le score local E est obtenu par une combinaison linéaire entre un score pour la continuité C , et un score pour la minceur T locale (T).

$$E = \gamma C + (1 - \gamma)T \quad (4.22)$$

Le critère de continuité est parfaitement satisfait ($C = 1$) si, dans une direction perpendiculaire à la direction du gradient au pixel central, il y a deux pixels adjacents à ce pixel central. Le critère de minceur locale est totalement satisfait ($T = 1$) s'il n'y a pas d'autres pixels contours dans le voisinage 3×3 . Selon que ces deux conditions sont plus ou moins bien remplies, les deux scores prennent des valeurs dans l'intervalle $[0, 1]$. Plus le critère de Kitchen et Rosenfeld est grand, la segmentation est bonne.

4.6.2.1.2 Critère de Leving et Nazif :

Des critères définis par Levine et Nazif [110] permettent d'évaluer deux types de contours :

1 -les contours séparant deux objets différents de l'image. Ils sont évalués par le contraste entre régions, de part et d'autre du contour.

Soit F un contour, mi l'intensité dans la région R_i , l_i la longueur de la frontière commune entre la région R_i et F . Ce type de critère est défini par :

$$C_j = \frac{|F_g - F_d|}{F_g - F_d} \quad (4.23)$$

Où

- $F_g = \sum l_{ig}$ somme sur les régions situées à gauche de F ;
- $F_d = \sum l_{id}$ somme sur les régions situées à droite de F .

2- les lignes qui traversent un objet, sans qu'il y ait une différence de niveau de gris (couleur) ou de textures ; elles sont évaluées par le gradient moyen le long de la ligne.

$$g_j = \frac{G}{\max - \min} \quad (4.24)$$

Avec

- G est le gradient moyen le long de la ligne ;
- $\max$ et $\min$ sont respectivement les valeurs maximale et minimale de l'attribut (couleur ou intensité) de l'ensemble des pixels des régions bordant F .

Dans le cas d'une image couleur, les calculs sont effectués séparément sur chaque canal et fournissent un vecteur de mesures.

4.6.2.1.3 Critère de Han et Kim :

Peli et al [111] ont proposé un critère d'ambiguïté mesurée via une approche floue. Il permet de quantifier la justesse du contour obtenu.

Trois mesures sont utilisées pour calculer l'ambiguïté : l'existence, la localisation et la disposition. L'ambiguïté d'existence et l'ambiguïté de localisation sont dérivées d'une généralisation de la représentation des frontières en utilisant des ensembles flous.

Cette méthode est utilisée notamment pour la recherche de paramètres optimaux (seuils) pour une méthode de segmentation donnée. Le jeu de paramètres de la méthode qui produit le moins d'erreur d'ambiguïté globale est alors le plus adapté.

4.6.2.2 Évaluation de la segmentation en région :

Pour un bon résultat de segmentation, les trois conditions suivantes doivent être satisfaites :

- les régions doivent être uniformes et homogènes ;
- l'intérieur des régions doit être simple et sans trop de petits trous ;
- les régions adjacentes doivent présenter des valeurs significativement différentes pour les caractéristiques d'uniformité.

Dans ce qui suit, nous allons donner quelques critères d'évaluation de la segmentation en région.

4.6.2.2.1 Critère de Borsotti :

Ce critère est basé sur trois paramètres : le nombre de régions, l'aire des régions et la couleur moyenne de chaque région. Borsotti [112] est présenté leur critère par l'équation suivante :

$$C_B = \frac{1}{10000 \times A} \sqrt{N} \sum_{i=1}^N \left[\frac{e_i^2}{1 + \log A_i} + \frac{R(A_i)^2}{A_i^2} \right] \quad (4.25)$$

Avec

- A_i le nombre de pixels de la région R_i ;
- A le nombre total de pixels de l'image ;
- N représente le nombre de régions de l'image segmentée ;
- $R(A_i)$ est le nombre de régions ayant une aire égale à A_i ;
- e_i^2 correspond à l'erreur quadratique portant sur la couleur de la région R_i .

Une bonne segmentation sera caractérisée par un critère de Borsotti proche de 0.

4.6.2.2.2 Critères de Levine et Nazif :

Levine et Nazif [110] ont défini un critère qui calcule l'uniformité intra-région d'une caractéristique de région en fonction de la variance de cette caractéristique. Ce critère est défini comme suit :

$$LEV1(I_R) = 1 - \frac{1}{Card(I)} \sum_{k=1}^{N_R} \frac{[\sum_{s \in R_k} g_I(s) - \sum_{t \in R_k} g_I(t)]^2}{[\max_{s \in R_k} g_I(s) - \min_{s \in R_k} g_I(s)]^2} \quad (4.26)$$

Où

- I_R correspond au résultat de segmentation de l'image dans un ensemble de régions $R = R_1, \dots, R_{N_R}$ ayant N_R régions,
- $Card(I)$ correspond au nombre de pixels de l'image,
- $g_I(s)$ correspond à l'intensité de niveau de gris du pixel s de l'image I et il peut être généralisé à toute autre caractéristique (couleur, texture,...).

Complémentaire à l'uniformité de l'intra-région, [110] ont défini une mesure de disparité entre deux régions pour évaluer la dissemblance des régions dans un résultat de segmentation. La formule de la disparition inter-région totale est définie comme suit :

$$LEV2(I_R) = \frac{\sum_{k=1}^{N_R} W_{R_k} \sum_{j=1}^{N_R} \frac{P_{R_k \setminus R_j} |\bar{g}_I(R_k) - \bar{g}_I(R_j)|}{\bar{g}_I(R_k) + \bar{g}_I(R_j)}}{\sum_{k=1}^{N_R} W_{R_k}} \quad (4.27)$$

Où W_{R_k} est un poids associé à R_k qui peut dépendre de sa zone, par exemple, $\bar{g}_I$ est la moyenne du niveau de gris de R_k . $\bar{g}_I(R_k)$ peut être généralisé à un vecteur caractéristique calculé sur les valeurs de pixels de la région R_k comme pour $LEV1$. $P_{R_k \setminus R_j}$ correspond à la longueur du périmètre de la région R_k commune au périmètre de la région R_j .

4.6.2.2.3 Critère de Rosenberger :

Rosenberger [113] combine les disparités intra-région et inter-région de Levnie et Nazif. La disparité entre les régions est calculée par l'écart type normalisé des niveaux de gris dans chaque région. Il définit leur critère comme suit :

$$LEV3(I_R) = \frac{1}{2} \left(1 + \frac{1}{C_{N_R}^2 \sum_{i,j=1, i \neq j}^{N_R} \frac{|\bar{g}_I(R_i) - \bar{g}_I(R_j)|}{4} \sum_{i=1}^{N_R} \sigma^2 R_i} \right) \quad (4.28)$$

Où $C_{N_R}^2$ est le nombre de combinaisons de 2 régions parmi N_R .

Puisque nos approches sont des méthodes de segmentation non supervisée basés sur la segmentation en région. Nous mettons l'accent sur les critères de Borsotti, Levine et Nazif et Rosenberger. Le critère de Borsotti pour l'évaluation du proche quantique et les autres critères pour évaluer l'approche multicritère.

4.7 Applications :

4.7.1 Méthode de segmentation basée sur l'optimisation multiobjective pour les images satellites à très haute résolution spatiale :

Cette méthode [114] est basée sur la séparation de différentes classes de niveaux de gris de manière optimale selon certains critères, en utilisant des techniques typiques de segmentation d'images. Nous calculons le centre de gravité pour chaque région de l'image en niveaux de gris et le seuil de son histogramme [115] [116] [117]. Afin de montrer la faisabilité de la méthode proposée, nous comparerons, dans un premier temps, notre approche avec les méthodes OTSU et K-means en testant et en appliquant notre algorithme sur des images de synthèse. Dans un deuxième temps, nous évaluerons notre algorithme de classification de l'occupation et de l'utilisation des terres à l'aide d'une image satellite d'une zone urbaine sélectionnée.

De plus, pour évaluer cette méthode, nous utilisons à la fois le critère de Levine et Nazif et le critère de Rosenberger.

4.7.1.1 Evaluation de la fonction d'optimisation multiobjective développée :

L'amélioration de la fonction objective nécessite au préalable d'identifier l'apport de notre méthode. Nous précédonc par une comparaison entre deux équations 4.5 et 4.6.

Notre nouvelle fonction multiobjective (MOBJ2) est basée sur celle de Nakib[90] (MOBJ1) avec l'introduction de l'entropie dans la fonction multiobjective, et après on a testé cette fonction sur des images synthétiques et sur des images satellites à haute résolution spatiale, clairement, nous pourrions observer la contribution positive au processus de segmentation.

Le résultat de la segmentation est évidemment étonnant (voir Figure 4.4), et cela est bien entendu bien justifié par les critères d'évaluation obtenus dans le tableau 4.1.

Images	Seuil	Filtre	Valeurs des critères d'évaluation de Levine et Nazif					
			<i>Intra région</i> <i>Maximal</i>		<i>Inter région</i> <i>Minimal</i>		<i>Intra Inter région</i> <i>Minimal</i>	
			MOBJ1	MOBJ2	MOBJ1	MOBJ2	MOBJ1	MOBJ2
Synt.	2	2.5	0.0120	0.0372	0.2943	0.1834	0.5542	0.5310
Panc.	2	2.5	0.1129	0.1240	0.2635	0.2424	0.5350	0.5341

TABLE 4.1 – Les valeurs des critères d'évaluation de Levine et Nazif des deux fonctions d'optimisation multiobjectives (MOBJ1 et MOBJ2).






Images Originales		Segmentation par la méthode	
		Multiobjectif 1	Multiobjectif 2
Synthétique			
			

FIGURE 4.4 – Segmentation d’images par les deux fonctions d’optimisation multiobjectives.

4.7.1.2 Base de données :

Afin de tester les algorithmes, nous avons considéré des images synthétiques de types niveau de gris et couleur, en second lieu, l’approche a été validée sur des images réelles de type satellitaires à haute résolution.

4.7.1.2.1 Images synthétiques :

Notre choix a porté sur les images ImgeSynt1, ImgeSynt2 et ImgeSynt3 de niveau de gris qui sont importées de la base de données [118]. Les images sont de même taille 256×256 pixels, codées sur 8 bits. Elles ont une forme de champignon, et sont composées de régions uniformes et texturées. Le tableau (4.2 illustre les résultats obtenus par notre méthode et leurs comparaisons avec les méthodes Otsu et K-means, Les résultats relativement meilleurs.

Images	Seuil	Filtre	Valeurs des critères d'évaluation de Levine et Nazif et Rosenberger								
			Critère intra region <i>LEV1</i>			Critère inter region <i>LEV2</i>			Intra Inter région <i>LEV3</i>		
			<i>Maximum</i>			<i>Minimum</i>			<i>Minimum</i>		
			Otsu	K-means	MOBJ2	Otsu	K-means	MOBJ2	Otsu	K-means	MOBJ2
ImagSyn1	1.3	1	0.0105	0.0263	0.0335	0.2473	0.2217	0.1826	0.5503	0.5509	0.5397
ImagSyn2	1.3	1.5	0.0231	0.0246	0.0306	0.1936	0.2142	0.1789	0.5442	0.5490	0.5334
ImagSyn3	0.5	1.5	0.0265	0.0292	0.0331	0.1623	0.1725	0.1469	0.5447	0.5517	0.5328
ImagSyn4	0.23	0.5	0.0425	0.0412	0.0467	0.1718	0.1892	0.1706	0.5500	0.5597	0.5374

TABLE 4.2 – les valeurs d'évaluation des différentes méthodes pour les images synthétiques.














	Images Synthétiques	Image segmentée par la méthode		
		Otsu	K-Means	Multiobjectif
ImageSynt1				
ImageSynt2				
ImageSynt3				
ImageSynt4				

FIGURE 4.5 – Résultats de la segmentation des images synthétiques.

4.7.1.2.2 Images satellites "Image Quickbird" :




FIGURE 4.6 – zone d'étude – image panchromatique QuickBird – région d'intérêt pour l'image panchromatique (zones urbaines, forêt et rivière)

L'image Quickbird (Figure 4.6) retenue pour ce travail est une zone urbaine sélectionnée

de la province de Skhirate-Témara, au nord-ouest du Maroc, Elle est délimitée entre la longitude $\phi_1 = -6^\circ 57' 58.87'' W$ et la latitude $\lambda_1 = 33^\circ 55' 35.99'' N$ et longitude $\phi_2 = -7^\circ 0' 55.08'' W$ et la latitude $\lambda_2 = 33^\circ 56' 34.57'' N$ et couvre environ 90 Km^2 . Cette image a été prise le 15 juin 2006.

L'image Quickbird fournit des données multispectrales de 16 bits dans les bandes rouge, verte, bleue et proche infrarouge à $2,41m \times 2,41m$ de résolution spatiale et une autre bande panchromatique de 11 bits à une résolution de $0,6m \times 0,6m$ (Figure 4.6). Pour produire des images multispectrales à haute résolution, les bandes multispectrales sont affûtées à une résolution de $0,6m$ en utilisant une bande panchromatique basée sur la méthode de Pansharp. Le tableau (4.3) donne les caractéristiques des bandes multispectrales.

Bande	Longueur d'onde (nm)	Résolution Spatial (m)
Bleu	450-520 (485)	2.41 x 2.41
Vert	520-600 (560)	
Rouge	630-690 (660)	
Proche Infra-Rouge	760-900 (830)	
Panchromatique	450-900 (675)	0.61 x 0.61

TABLE 4.3 – Caractéristiques des bandes multispectrales de l'image QuickBird MS.













Images		Image segmentée par la méthode		
Panchromatiques		Otsu	K-Means	Multiobjectif
Imagesat1				
Imagesat2				
Imagesat3				
Imagesat4				

FIGURE 4.7 – Résultats de la segmentation des images panchromatiques.

Valeurs des critères d'évaluation de Levine et Nazif											
Images	Seuil	Filtre	Intra région Maximal			Inter région Minimal			Intra Inter région Minimal		
			Otsu	K-Means	MOBJ2	Otsu	K-Means	MOBJ2	Otsu	K-Means	MOBJ2
ImagSat1	1.66	1.5	0.0612	0.0704	0.0709	0.3747	0.2952	0.2912	0.5556	0.5443	0.5437
ImagSat2	4	3	0.0898	0.0858	0.1286	0.2940	0.3158	0.2901	0.5865	0.5957	0.5789
ImagSat3	4	3	0.1015	0.1002	0.1246	0.3059	0.3355	0.3011	0.5860	0.5975	0.5856
ImagSat4	2.6	1	0.1026	0.0996	0.1338	0.2900	0.3054	0.2826	0.5853	0.5914	0.5796

TABLE 4.4 – Valeurs d'évaluation du critère de Levine et Nazif pour diverses méthodes (Images panchromatiques).

4.7.1.3 Résultats expérimentaux et discussion :

Le seuillage basé sur la variance au sein d'une classe tend à classer une image comme objet. Les expériences présentées ici concernent à la fois la classification des pixels d'une image synthétique et la classification de notre image Quickbird dans les différentes classes d'occupation et d'utilisation des terres.

Afin d'évaluer la technique proposée, nous avons mené la première phase d'expérimentation sur des images de synthèse. Nous avons choisi une première image, qui contient une texture pour étudier l'influence de petites régions. Nous avons remarqué que les valeurs des critères inter-région et intra-inter-région de notre méthode proposée sont inférieures à celles fournies par celle d'Otsu et de K-means et l'autre intra-région est supérieur à celles fournies par celle de K-means et d'Otsu . Les mêmes résultats ont été obtenus lors du traitement d'autres images synthétiques ayant des propriétés morphologiques différentes. La figure 4.5 présente les résultats segmentés pour les images synthétiques et la figure 4.7 présente les résultats segmentés pour les images panchromatiques. De plus, pour évaluer la technique proposée, nous avons utilisé l'évaluation des critères de Levine et Nazif. Les tableaux 4.2 et 4.4 montrent que la méthode proposée est plus performante que les méthodes d'Otsu et de K-means.

La deuxième phase d'expérimentation a été menée sur un ensemble d'images récapitulatives avec un VHSR (image panchromatique avec une résolution spatiale de $0,61 \text{ m} \times 0,61 \text{ m}$). Tout en ajustant le seuil et les coefficients de filtrage pour segmenter chaque image, nous avons également calculé leurs centres de gravité ainsi que leur critère d'uniformité inter-région, intra-région et intra-inter région de Levine et Nazif. Cela a été fait pour la méthode multicritère, la méthode Otsu et la méthode K-means.

Pour évaluer la qualité des résultats de segmentation dans le cas d'images réelles, qui contiennent généralement plusieurs dégradations inconnues, la deuxième phase de cette étude expérimentale comparative a été menée et évaluée à l'aide d'une image réelle en niveaux de gris et d'un ensemble d'images satellites VHSR. Nous pourrions déduire des valeurs obtenues des critères d'évaluation (Tableau 4.4), qui restent constamment inférieures à celles obtenues en utilisant l'algorithme d'Otsu, que la méthode d'optimisation

multiobjectif fournit des résultats plus stables et plus fiables, notamment dans le cas d'images satellites à haute résolution.

4.7.2 Classification des images satellites basée sur l'approche quantique et l'entropie de Tsallis :

Des études précédentes sur l'extraction d'informations par segmentation d'images satellite ont montré une relative satisfaction. La théorie quantique qui prend en compte davantage d'informations sur le processus de classification des images satellite et qui s'appuie sur l'analyse hiérarchique des histogrammes 2D a prouvé sa capacité à résoudre des problèmes complexes [117] .

En pratique, l'application d'une telle méthode à des images à très haute résolution spatiale conduit, dans certaines situations, à des résultats imprécis (certaines régions d'intérêt distinctes étant classées comme homogènes). Cela est dû à deux problèmes critiques pour la segmentation des images couleur : (1) la manière dont la méthode de segmentation doit être utilisée; et (2) la manière dont l'espace colorimétrique doit être adopté [119]. Il a été démontré que, dans les problèmes de classification non supervisés, l'histogramme de seuillage est une méthode appropriée permettant de segmenter une large classe d'images avec une faible complexité de calcul [119] [46].

Les algorithmes de classification basés sur l'analyse d'histogramme 2D, obtenue par la projection de l'histogramme multidimensionnel sur deux plans de couleur, ont été développés et utilisés avec succès [115] [120].

En général, cette méthode est divisée en deux parties. La première consiste en une analyse théorique de la nouvelle méthode numérique de segmentation des couleurs, basée sur l'analyse hiérarchique d'histogrammes 2D [115] [121] [121] qui est construit en utilisant la fonction d'onde pour une particule dans une boîte 2D [117]. Afin de considérer le désordre de l'information nous proposons d'introduire l'entropie de Tsallis.

4.7.2.1 Méthode proposée :

Tsallis a proposé une généralisation de la célèbre mesure entropique de Boltzmann-Gibbs (BG) [122], connue aujourd'hui sous le nom « entropie de Tsallis ». L'entropie de Tsallis est une généralisation à un paramètre de l'entropie de Shannon, qui récupère les statistiques habituelles de Boltzmann-Gibbs basées sur l'entropie de Shannon [123]. L'entropie de Tsallis est définie comme :

$$S_q = \frac{1 - \sum_{i=1}^k (p_i)^q}{q - 1} \quad (4.29)$$

Où k est le nombre total de possibilités du système et le nombre réel q désigne un indice entropique qui caractérise le degré de non-extensibilité.

Aujourd'hui, on constate qu'un nombre de plus en plus important de systèmes naturels et artificiels sont étudiés au moyen de l'entropie de Tsallis [124] de toutes les recherches qui y font référence, une grande partie, au moins plus d'un millier, porte sur son application en traitement d'image. L'entropie de Tsallis entre dans le traitement d'image à travers le problème de segmentation d'image.

Puisque dans l'approche quantique (Comme vu en section ?? dans ce chapitre) le $|\Psi|^2$ est une densité de probabilité, nous avons proposé de remplacer $\sum_{i=1}^k (p_i)$ par $|\Psi|^2$, donc l'entropie de Tsallis deviendra la suivante :

$$S_q = \frac{1 - (|\Psi|^2)^q}{q - 1} \quad (4.30)$$

L'objectif est de fusionner en différentes classes les pixels qui présentent une entropie similaire à celle de Tsallis dans l'image couleur, de manière non supervisée. L'algorithme fonctionne à partir de l'un des trois histogrammes 2D de l'image couleur $(Sq(r), Sq(g))$ ou $(Sq(r), Sq(b))$ ou $(Sq(b), Sq(g))$.

Où

$$S_q(r) = \frac{1 - (|\Psi(r)|^2)^q}{q - 1} \quad (4.31)$$

$$S_q(g) = \frac{1 - (|\Psi(g)|^2)^q}{q - 1} \quad (4.32)$$

$$S_q(b) = \frac{1 - (|\Psi(b)|^2)^q}{q - 1} \quad (4.33)$$

Un histogramme 2D d'une image couleur I représente $P(S_x, S_y)$ est le nombre de pixels dans l'image I présentant l'entropie de Tsallis (S_x, S_y) . Puisque chaque axe d'entropie de Tsallis de I est quantifié sur 256 niveaux, l'histogramme 2D peut être représenté par une image J dont la résolution spatiale est égale à 256×256 . La valeur $P(S_x, S_y)$ du pixel de coordonnées (S_x, S_y) dans J est obtenue par une contraction dynamique linéaire de l'histogramme entre 1 et $M = \min(P_{\max}, 255)$.

$$P_n(x_1, x_2) = \text{round}\left[\frac{(M - 1)p(x_1, x_2) - Mp_{\max} + p_{\min}}{p_{\max} - p_{\min}}\right] \quad (4.34)$$

Où : $P_{\min}$ et $P_{\max}$ sont respectivement les valeurs minimale et maximale de P .

4.7.2.2 Méthode de classification :

Nous utilisons l'algorithme de classification proposé par Clément [46] pour détecter les pics qui représentent les classes. Cette procédure est une version de l'algorithme classique de remplissage d'eau proposé par Vincent [125]. Un pic qualifié de significatif s'il représente une population supérieure ou égale à un seuil $d0$ (exprimé en pourcentage de la population totale dans l'image). Enfin, nous effectuons l'algorithme de segmentation par reclassement des pixels non classés dans les classes déterminées, selon la distance euclidienne ou la distance de Mahalanobis.

En outre, pour évaluer la méthode proposée, nous avons utilisé l'évaluation des critères de Borsotti.

4.7.2.3 Base de données :

Les expériences présentées ici concernent la classification des pixels de l'image synthétique et la classification de notre image QuickBird dans les différentes classes

d'occupation du sol et d'utilisation du sol.

4.7.2.3.1 Images synthétiques :

Pour évaluer la méthode proposée, l'image couleur synthétique est sélectionnée : 348X416, qui comprend un cercle, une étoile et un losange a été construit par le logiciel paint(figure 4.12).



FIGURE 4.8 – L'image synthétique sélectionnée

	Distance Euclidienne	Distance Mahalanobis
Plan RG	22.8231	25.0521
Plan RB	157.2987	168.6889
Plan GB	465.1237	509.2243

TABLE 4.5 – Valeurs de la fonction d'évaluation Q de Borsotti pour l'image synthétique par la méthode proposée




FIGURE 4.9 – Résultat de segmentation pour image synthétique

	Distance Euclidienne	Distance Mahalanobis
Plan RG	116.6657	111.6151
Plan RB	685.3258	651.0842
Plan GB	689.7565	702.5900

TABLE 4.6 – Valeurs de la fonction d'évaluation Q de Borsotti pour l'image synthétique par la méthode précédente [117]

4.7.2.3.2 Images satellites "Image Quickbird" :

L'image Quickbird (Figure 4.10) retenue pour ce travail est une zone urbaine sélectionnée de la province de Skhirate-Témara, au nord-ouest du Maroc, Elle est délimitée entre la longitude $\phi_1 = -6^{\circ}57'58.87''W$ et la latitude $\lambda_1 = 33^{\circ}55'35.99''N$ et longitude $\phi_2 = -7^{\circ}0'55.08''W$ et la latitude $\lambda_2 = 33^{\circ}56'34.57''N$ et couvre environ 90 Km^2 .

Sur la figure 4.10, une composition de couleurs RGB de l'image est présentée. Il est évident que la variété des unités d'occupation du sol et d'utilisation des terres existe dans la zone. Cette image a été prise le 15 juin 2006. La résolution de l'image multispectrale est de 2,4 mètres par les canaux Rouge, Vert et Bleu ainsi que par le canal Proche Infra-Rouge. Le tableau (4.3) donne les caractéristiques des bandes multispectrales.



FIGURE 4.10 – QuickBird RGB Image - Zone d'étude sélectionnée.





Images Originales		Méthode proposée	Méthode précédente [117]
Image (a)			
Image (b)			

FIGURE 4.11 – Résultat de segmentation pour l'image QuickBird

<i>Image</i>	<i>Methode</i>	<i>Plan RG</i>		<i>Plan RB</i>		<i>Plan GB</i>	
		<i>Distance</i>		<i>Distance</i>		<i>Distance</i>	
		Euclidienne	Mahalanobis	Euclidienne	Mahalanobis	Euclidienne	Mahalanobis
Image (a)	Méthode proposée	245.1530	2.2535e+03	259.7280	2.1195e+03	542.8301	3.5249e+03
	Méthode de [117]	607.0267	5.2204e+03	473.9130	4.3942e+03	794.3306	3.9471e+03
Image (b)	Méthode proposée	54.3914	88.2856	73.7527	101.4335	138.1049	178.1325
	Méthode de [117]	246.4929	246.4929	213.4406	213.4406	323.3000	323.3000

TABLE 4.7 – Valeurs de la fonction d'évaluation Q de Borsotti pour l'image QuickBird

4.7.2.4 Résultats expérimentaux et discussion :

La Figure 4.9 montre les images segmentées à chaque plan (RG RB GB) dans l'espace colorimétrique (RGB). De plus, le résultat est présenté avec deux distances colorimétriques différentes ; Euclidien et Mahalanobis. Afin de quantifier le résultat de la segmentation qualitative, la fonction Q est considérée. Le tableau 4.5 présente différentes valeurs de Q de la méthode proposée pour l'image synthétique. On peut voir que les meilleurs scores pour l'évaluation de la « qualité » de segmentation sont de **22,8231** sont donnés avec le plan RG en utilisant la distance euclidienne.

Afin d'évaluer les performances de notre nouvelle méthode, nous l'avons comparée à la méthode précédente [117]. Les différentes valeurs de la fonction d'évaluation Q de segmentation pour image synthétique telles que les données dans le tableau 4.6 pour la méthode précédente [117] et dans le tableau 4.5 pour la méthode proposée. Par conséquent, il est clair que les performances de segmentation à l'aide de la méthode précédente donnent un score très élevé pour les valeurs de la fonction d'évaluation Q, ce qui signifie que notre méthode proposée doit être prise en compte pour un traitement ultérieur.

Pour l'image QuickBird, nous nous intéressons à la sélection de zone dans la figure 4.10 (a et b). Nous avons étudié les résultats de la segmentation de la méthode proposée selon le plan de l'espace utilisé (RG, RB ou GB), et selon la distance colorimétrique utilisée dans l'étape de décision à savoir la distance euclidienne ou distance de Mahalanobis. Les mesures de validité d'une image QuickBird sont résumées dans le tableau 4.7.

Les images correspondantes sont affichées dans la figure 4.11 pour une illustration typique. Comme dans le présent travail, la segmentation des images est considérée comme un problème de classification, nous avons comparé la méthode proposée avec la méthode de [117].

Dans notre méthode, les valeurs de la fonction d'évaluation Q pour les images QuickBird (Figure 4.11) montrent que la meilleure segmentation est donnée en utilisant les plans (RG) de l'espace RGB et la distance euclidienne dans l'étape de décision. La valeur de la fonction d'évaluation Q est la plus petite et est égale à **245,1530** pour l'image QuickBird (a) et à

54, 3914 pour l'image QuickBird (b).

Dans la méthode précédente [117], nous avons trouvé le même résultat (distance et plan) pour la méthode proposée, mais avec des valeurs d'évaluation Q différentes qui sont **607, 0267** pour l'image QuickBird (a) et **246, 4929** pour l'image QuickBird (b). Habituellement, de même que les images QuickBird et selon le tableau 4.7, nous avons conclu que la méthode proposée est meilleure que la méthode précédente [117].

4.7.2.5 Influence du paramètre q dans la segmentation d'images :

Dans l'entropie de Tsallis, le paramètre q est généralement interprété comme une quantité caractéristique du degré de non-amplitude d'un système.

En segmentation d'images, la non-extensibilité d'un système peut s'expliquer par l'existence de corrélations entre pixels d'un même objet dans l'image. Ces corrélations peuvent être organisées sous forme de corrélations à longue portée dans le cas d'images qui exposent des pixels hautement corrélés à des niveaux de luminance et à une complétion spatiale [126].

Pour démontrer l'influence du paramètre q sur le résultat de la segmentation, nous prenons différentes valeurs de $q(0, 25, 0, 55, 0, 75, 1, 25 \text{ et } 1, 55)$ pour segmenter l'image synthétique et les images QuickBird par la méthode présentée.

D'après les tableaux 4.8, 4.9 et 4.10 les valeurs de la fonction d'évaluation Q sont différentes pour les différents q quelle que soit la distance utilisée Mahalanobis ou Euclidienne de la segmentation des images synthétiques et QuickBird, on constate que la valeur de la fonction d'évaluation Q est inférieure si $q = 0, 55$. Alors la meilleure segmentation est pour $q = 0, 55$.

Image synthétique						
Valeurs de q	Plan RG		Plan RB		Plan GB	
	Distance		Distance		Distance	
	Euclidienne	Mahalanobis	Euclidienne	Mahalanobis	Euclidienne	Mahalanobis
$q=0.25$	38.6447	59.7391	178.5150	591.2773	Inf	564.5984
$q=0.55$	22.8231	25.0521	157.2987	168.6889	465.1237	509.2243
$q=0.75$	38.6447	59.7391	178.5150	591.2773	Inf	564.5984
$q=1.25$	131.4177	127.1201	847.6654	788.2193	784.8592	766.3281
$q=1.55$	147.1975	144.6244	1.0478e+03	2.8987e+03	992.3628	834.4977

TABLE 4.8 – Valeurs de la fonction d'évaluation Q pour l'image synthétique par différentes valeurs du paramètre q

Image QuickBird (a)						
Valeurs de q	Plan RG		Plan RB		Plan GB	
	Distance		Distance		Distance	
	Euclidienne	Mahalanobis	Euclidienne	Mahalanobis	Euclidienne	Mahalanobis
$q=0.25$	449.9427	755.9829	346.2549	613.6017	629.0153	1.9827e+03
$q=0.55$	245.1530	2.2535e+03	259.7280	2.1195e+03	542.8301	4.5249e+03
$q=0.75$	449.9427	755.9829	346.2549	613.6017	629.0153	1.9827e+03
$q=1.25$	1.9377e+03	6.7239e+03	1.5304e+03	6.3007e+03	2.0784e+03	6.4975e+03
$q=1.55$	2.6862e+03	5.7980e+03	2.1893e+03	6.0145e+03	3.0158e+03	4.5379e+03

TABLE 4.9 – Différentes valeurs de la fonction d'évaluation Q par différentes valeurs du paramètre q pour l'image QuickBird (a)

Image QuickBird (b)						
Valeurs de q	Plan RG		Plan RB		Plan GB	
	Distance		Distance		Distance	
	Euclidienne	Mahalanobis	Euclidienne	Mahalanobis	Euclidienne	Mahalanobis
$q=0.25$	291.5142	807.0307	278.2939	626.2160	361.3200	952.3272
$q=0.55$	54.3914	88.2856	73.7527	101.4335	138.1049	178.1325
$q=0.75$	291.5142	807.0307	278.2939	626.2160	361.3200	952.3272
$q=1.25$	158.6870	843.5706	168.8102	903.7662	181.1269	764.6340
$q=1.55$	161.6576	841.9707	171.5671	910.1197	205.4000	776.9206

TABLE 4.10 – Différentes valeurs de la fonction d'évaluation Q par différentes valeurs du paramètre q pour l'image QuickBird (b)

4.7.3 Segmentation d'images satellite basée sur l'approche quantique et l'entropie Havrda-Charvat :

Dans cette méthode, nous présentons une nouvelle segmentation fondée sur la théorie de la mécanique quantique et sur l'entropie de Havrda-Charvat.

La segmentation a été réalisée à l'aide d'une méthode de classification non supervisée utilisant l'analyse hiérarchique des histogrammes 2D, construits à l'aide de la fonction d'onde et de l'entropie Havrda – Charvat. Nous améliorons la qualité de la méthode de classification en reclassant les pixels non classés dans les classes définies par la distance euclidienne et la distance de Mahalanobis.

L'approche proposée a d'abord été testée sur l'image de synthèse ; elle a été appliquée à la classification de l'environnement pour les données QuickBird d'une zone urbaine sélectionnée dans la région de Rabat-Salé-Kenitra, préfecture de Skhirate-Temara, Maroc. Le résultat de classification obtenu est plus satisfaisant que celui obtenu dans l'étude précédente [117]. La méthode de développement est très prometteuse et doit être approfondie.

4.7.3.1 Méthode proposée :

Havrda et Charvat ont défini l'entropie de degré [127] en 1967. Elle est définie comme suit :

$$H_n^\alpha = \frac{1}{1 - 2^{1-\alpha}} \left(1 - \sum_{i=1}^n p_i^\alpha \right) \quad (4.35)$$

Où :

- α est un paramètre réel positif différent de un ;
- $P = (p_1, p_2, \dots, p_n) \in \Delta_n$;
- $\Delta_n = \{(p_1, p_2, \dots, p_n) \mid p_i \geq 0, i = 0, 1, \dots, n, n \geq 2, \sum_{i=1}^n p_i = 1\}$;
- p_i sont les probabilités des pixels dans l'histogramme.

Comme dans l'approche quantique (Comme vu en section ?? dans ce chapitre) le $|\Psi|^2$ est une densité de probabilité, nous avons proposé de remplacer $\sum_{i=1}^k (p_i)$ par $|\Psi|^2$, donc

l'entropie de Havrda-Charvat deviendra la suivante :

$$H_n^\alpha = \frac{1 - (|\Psi|^2)^\alpha}{1 - 2^{1-\alpha}} \quad (4.36)$$

L'objectif est de fusionner en différentes classes les pixels qui présentent une entropie Havrda-Charvat similaire dans l'image couleur, de manière non supervisée. L'algorithme fonctionne à partir de l'un des trois histogrammes 2D de l'image couleur $(H_\alpha(r), H_\alpha(g))$ ou $(H_\alpha(r), H_\alpha(b))$ ou $(H_\alpha(b), H_\alpha(g))$.

Où :

$$H_n(r)^\alpha = \frac{1 - (|\Psi(r)|^2)^\alpha}{1 - 2^{1-\alpha}} \quad (4.37)$$

$$H_n(g)^\alpha = \frac{1 - (|\Psi(g)|^2)^\alpha}{1 - 2^{1-\alpha}} \quad (4.38)$$

$$H_n(b)^\alpha = \frac{1 - (|\Psi(b)|^2)^\alpha}{1 - 2^{1-\alpha}} \quad (4.39)$$

4.7.3.2 Méthode de classification :

Comme la méthode précédente, nous utilisons l'algorithme de classification proposé par Clément [46] pour détecter les pics qui représentent les classes. Cette procédure est une version de l'algorithme classique de remplissage d'eau proposé par Vincent [125]. Un pic qualifié de significatif s'il représente une population supérieure ou égale à un seuil $d0$ (exprimé en pourcentage de la population totale dans l'image). Enfin, nous effectuons l'algorithme de segmentation par reclassement des pixels non classés dans les classes déterminées, selon la distance euclidienne ou la distance de Mahalanobis.

Nous avons utilisé l'évaluation des critères de Borsotti pour évaluer notre méthode proposée.

4.7.3.3 Base de données :

Les expériences présentées ici concernent la classification des pixels de l'image synthétique et la classification de notre image QuickBird dans les différentes classes d'occupation du sol et d'utilisation du sol.

4.7.3.3.1 Image synthétique :

Pour évaluer la méthode proposée, l'image couleur synthétique est sélectionnée : 348X416, qui comprend un cercle, une étoile et un losange a été construit par le logiciel paint (figure 4.12).




FIGURE 4.12 – l'image synthétique sélectionnée

PLAN	Distance Euclidienne		Distance Mahalanobis	
	Méthode de [117]	Méthode proposée	Méthode de [117]	Méthode proposée
RG	689.7565	465.1237	702.59	509.2243
RB	Inf	707.9159	Inf	Inf
GB	142.1527	123.1113	Inf	125.1779

TABLE 4.11 – Valeurs de la fonction d'évaluation Q de Borsotti pour l'image synthétique par la méthode proposée







	Méthode de [117]	Méthode proposée
Plan RG		
Plan RB		
Plan GB		

FIGURE 4.13 – Résultats de segmentation pour image synthétique utilisant la distance de Mahalanobis







	Méthode de [117]	Méthode proposée
Plan RG		
Plan RB		
Plan GB		

FIGURE 4.14 – Résultats de segmentation pour image synthétique utilisant la distance Euclidienne

4.7.3.3.2 Images satellites "Image Quickbird" :

L'image Quickbird (Figure 4.15) retenue pour ce travail est une zone urbaine sélectionnée de la province de Skhirate-Témara, au nord-ouest du Maroc, Elle est délimitée entre la longitude $\phi_1 = -6^{\circ}57'58.87''W$ et la latitude $\lambda_1 = 33^{\circ}55'35.99''N$ et longitude $\phi_2 = -7^{\circ}0'55.08''W$ et la latitude $\lambda_2 = 33^{\circ}56'34.57''N$ et couvre environ 90 Km^2 .

Sur la figure 4.15, une composition de couleurs RGB de l'image est présentée. Il est évident que la variété des unités d'occupation du sol et d'utilisation des terres existe dans

la zone. Cette image a été prise le 15 juin 2006. La résolution de l'image multispectrale est de 2,4 mètres par les canaux Rouge, Vert et Bleu ainsi que par le canal Proche Infra-Rouge. Le tableau (4.3) donne les caractéristiques des bandes multispectrales.




FIGURE 4.15 – QuickBird RGB Image - Zone d'étude sélectionnée.

<i>Image</i>	<i>Methode</i>	<i>Plan RG</i>		<i>Plan RB</i>		<i>Plan GB</i>	
		<i>Distance</i>		<i>Distance</i>		<i>Distance</i>	
		Euclidienne	Mahalanobis	Euclidienne	Mahalanobis	Euclidienne	Mahalanobis
Image (a)	Méthode proposée	903.3648	893.7730	1.2864e+03	1.5818e+03	907.9956	1.4150e+03
	Méthode de [117]	764.8482	1.6930e+03	1.5424e+03	1.9968e+03	1.1350e+03	2.2893e+03
Image (b)	Méthode proposée	192.9088	193.7139	75.5071	96.6368	56.8408	91.7473
	Méthode de [117]	271.5032	353.2472	121.8697	138.0706	93.2694	193.0969

TABLE 4.12 – Valeurs de la fonction d'évaluation Q de Borsotti pour l'image QuickBird







	Méthode de [117]	Méthode proposée
Plan RG		
Plan RB		
Plan GB		

FIGURE 4.16 – Résultats de segmentation pour l'image Quikbird (a) en utilisant la distance euclidienne







	Méthode de [117]	Méthode proposée
Plan RG		
Plan RB		
Plan GB		

FIGURE 4.17 – Résultats de segmentation pour l'image Quikbird (a) en utilisant la distance de Mahalanobis







	Méthode de [117]	Méthode proposée
Plan RG		
Plan RB		
Plan GB		

FIGURE 4.18 – Résultats de segmentation pour l'image Quikbird (b) en utilisant la distance euclidienne







	Méthode de [117]	Méthode proposée
Plan RG		
Plan RB		
Plan GB		

FIGURE 4.19 – Résultats de segmentation pour l'image Quikbird (b) en utilisant la distance de Mahalanobis

4.7.3.4 Résultats expérimentaux et discussion :

Les expériences décrites ici concernent la classification des pixels des deux images synthétiques et la classification de notre image QuickBird dans les différentes classes d'occupation et d'utilisation des terres.

Les figures 4.13 et 4.14 montrent les images segmentées à chaque plan (RG, RB et GB) dans l'espace colorimétrique (RGB). De plus, le résultat est présenté avec deux distances colorimétriques différentes, Euclidienne et Mahalanobis. Pour quantifier le résultat de la segmentation qualitative, la fonction Q est prise en compte. Le tableau 4.11 donne

différentes valeurs de Q d'image synthétique.

Afin d'évaluer les performances de notre nouvelle méthode, nous l'avons comparée à la méthode de Mechkouri et al [117]. D'après les valeurs de la fonction d'évaluation Q de segmentation pour les images de synthèse qui sont données dans le tableau 4.11, il apparaît clairement que la réalisation de segmentation selon la méthode de Mechkouri et al [117] donne un score très élevé pour les valeurs de la fonction d'évaluation Q , ce qui signifie que notre méthode proposée doit être prise en compte pour un traitement ultérieur.

En tant qu'image synthétique, pour évaluer les performances de notre nouvelle méthode par rapport à la méthode de Mechkouri et al [117], nous avons appliqué des images Quikbird (Figures 4.16, 4.17, 4.18 et 4.19) en utilisant la fonction d'évaluation Q .

Du tableau 4.12 qui tire les valeurs de la fonction d'évaluation Q de segmentation d'image QuickBird, il est sûr que la performance de segmentation par la méthode de Mechkouri et al [117] donne un score très élevé pour les valeurs de la fonction d'évaluation Q , ce qui signifie que notre méthode donne de meilleurs résultats que la méthode de Mechkouri et al [117].

De manière générale, comme pour les images QuickBird et selon le tableau 4.12, nous avons conclu que la méthode proposée est meilleure que la méthode de Mechkouri et al [117].

4.7.3.5 Influence du paramètre α dans la segmentation d'image :

Dans l'entropie de Havrda–Charvat, le paramètre α est généralement interprété comme une quantité caractéristique du degré de non-amplitude d'un système.

En segmentation d'images, la non-extensibilité d'un système peut s'expliquer par l'existence de corrélations entre pixels d'un même objet dans l'image. Ces corrélations peuvent être organisées sous forme de corrélations à longue portée dans le cas d'images présentant des pixels fortement corrélés aux niveaux de luminance et à la complémentation spatiale [126].

Pour montrer l'influence du paramètre α sur le résultat de la segmentation, nous prenons différentes valeurs de α (0, 25, 0, 75, 1, 25 et 1, 55) pour segmenter l'image synthétique et les images QuickBird par la méthode présentée.

D'après les tableaux 4.13, 4.14 et 4.15 les valeurs de la fonction d'évaluation Q sont différentes pour les différents α quelle que soit la distance utilisée Mahalanobis ou Euclidienne de la segmentation des images synthétiques et QuickBird.

Image synthétique						
Valeurs de α	Plan RG		Plan RB		Plan GB	
	Distance		Distance		Distance	
	Euclidienne	Mahalanobis	Euclidienne	Mahalanobis	Euclidienne	Mahalanobis
$\alpha = 0.25$	Inf	564.5984	118.4848	978.2959	60.3137	59.7045
$\alpha = 0.75$	478.4070	531.3716	Inf	Inf	Inf	Inf
$\alpha = 1.25$	784.8592	766.3281	Inf	Inf	799.8358	Inf
$\alpha = 1.55$	992.3628	834.4977	665.6844	639.3849	811.4984	Inf

TABLE 4.13 – Valeurs de la fonction d'évaluation Q pour l'image synthétique par différentes valeurs du paramètre α

Image QuickBird (a)						
Valeurs de q	Plan RG		Plan RB		Plan GB	
	Distance		Distance		Distance	
	Euclidienne	Mahalanobis	Euclidienne	Mahalanobis	Euclidienne	Mahalanobis
$\alpha = 0.25$	714.9009	755.9829	892.8741	1.7550e+03	571.8959	1.4005e+03
$\alpha = 0.75$	759.7993	1.3057e+03	1.4793e+03	1.8532e+03	1.5878e+03	2.0299e+03
$\alpha = 1.25$	1.9071e+03	2.5500e+03	1.9826e+03	2.6189e+03	2.5007e+03	3.1283e+03
$\alpha = 1.55$	1.4177e+03	2.5524e+03	2.2670e+03	2.8378e+03	2.4633e+03	2.8908e+03

TABLE 4.14 – Différentes valeurs de la fonction d'évaluation Q par différentes valeurs du paramètre α pour l'image QuickBird (a)

Image QuickBird (b)						
Valeurs de q	Plan RG		Plan RB		Plan GB	
	Distance		Distance		Distance	
	Euclidienne	Mahalanobis	Euclidienne	Mahalanobis	Euclidienne	Mahalanobis
$\alpha = 0.25$	232.8570	211.2849	101.9123	188.6602	137.5288	386.1377
$\alpha = 0.75$	217.3066	201.8603	157.0020	149.4499	68.0405	114.2247
$\alpha = 1.25$	141.0825	165.7547	177.0946	203.9845	325.2863	425.7976
$\alpha = 1.55$	427.6859	585.8287	720.2603	720.2603	441.9060	554.4607

TABLE 4.15 – Différentes valeurs de la fonction d'évaluation Q par différentes valeurs du paramètre α pour l'image QuickBird (b)

4.8 Conclusion :

D'abord, nous avons proposé une nouvelle méthode de segmentation multicritère basée sur la séparation de différentes classes de niveaux de gris de manière optimale selon certains critères et l'avons appliquée aux images synthétiques et images satellites de très haute résolution spatiale. Nous avons donc implémenté une méthode de segmentation basée sur la fonction d'optimisation multiobjectif développée (MOBJ2) et prenons en compte l'entropie. Nous avons testé la fonction par rapport à celle de Nakib [90] (MOBJ1) tout en faisant appel aux critères d'évaluation de Levine et Nazif et avons obtenu de bons résultats.

Nous avons appliqué le MOBJ2 selon la segmentation d'images multiclassées telles que des images synthétiques et des échantillons d'image panchromatique de très haute résolution spatiale afin d'évaluer la fonction MOBJ2 par rapport à celle de l'OTSU et des K-means disponibles dans MATHLAB. L'évaluation de la segmentation en introduisant les critères d'évaluation de Levine et Nazif montre que la fonction multiobjectif développée est meilleure que la méthode OTSU et les K-means.

Ensuite, nous avons présenté une méthode de classification des images satellite basée sur l'approche quantique et l'entropie de Tsallis en s'appuyant sur la densité de probabilité, et nous l'avons comparée à la méthode précédente de Mechkouri et al [117]. Nous avons amélioré la qualité de la stratégie de classification en renommant les pixels, qui ne sont pas classés dans les classes décidées selon la distance euclidienne et Mahalanobis.

Nous avons testé notre méthode en utilisant deux types d'images, sur l'image synthétique et d'autre part elle l'a appliquée à la classification de l'environnement urbain pour les données QuickBird d'une zone urbaine sélectionnée de la région. Nous nous sommes appuyés sur le critère Borsotti pour prouver la performance de la segmentation.

Dans les expériences, les plans (RG) de l'espace RGB et la distance euclidienne dans l'étape de décision, fournissent des informations appropriées pour une meilleure segmentation. Les résultats de la comparaison avec la méthode de Mechkouri et al [117] ont montré que l'algorithme proposé était capable de segmenter l'image QuickBird. Le coefficient Tsallis q peut être utilisé comme valeur réglable et peut jouer un rôle essentiel

en tant que paramètre de réglage dans la segmentation de l'image.

Puis, nous avons proposé une méthode de classification des images satellite fondée sur l'approche quantique et l'entropie de Havrda – Charvat en s'appuyant sur la densité de probabilité, et nous l'avons comparée à la méthode de Mechkouri et al [117]. Nous avons amélioré la qualité de la stratégie de classification en renommant les pixels dont le produit n'est pas classé dans les classes décidées selon la distance d'Euclide et de Mahalanobis.

Nous avons essayé notre méthode avec deux types d'images, sur l'image synthétique a été appliquée à la classification de l'environnement urbain pour les données QuickBird d'une zone urbaine choisie de la région. Nous nous sommes appuyés sur les critères de Borsotti pour démontrer la performance de la segmentation.

Les résultats de la comparaison avec la méthode de Mechkouri et al [117] ont montré que l'algorithme proposé était capable de segmenter l'image synthétique et l'image QuickBird. Le coefficient Havrda – Charvat α peut être utilisé comme valeur réglable et peut constituer un élément nécessaire en tant que paramètre de réglage dans la segmentation de l'image.

Enfin, les méthodes de développement sont extrêmement encourageantes et doivent être davantage explorées.

Conclusion générale et perspectives

CONCLUSION GENERALE

La segmentation d'images joue un rôle essentiel dans l'interprétation du contenu d'une scène donnée.

Dans le cadre de cette thèse, nous avons porté notre attention sur la segmentation basée sur les régions des images multispectrales du satellite QuickBird. Pour cette raison trois approches de segmentation liées à des seuillages d'histogrammes $2D$ ont été suggérés :

- La première est basée sur l'optimisation de la fonction multiobjectif appliquée aux images de très haute résolution spatiale du satellite QuickBird ;
- La deuxième est basée sur un théorème de quantique et l'entropie de Tsallis appliquée aux images multispectrales ;
- La troisième est basée sur la physique quantique par la résolution de la fonction d'onde et l'entropie de Havrda-Charvat.

L'objectif essentiel visé par cette thèse est de développer des techniques de segmentation basées sur les régions, qui prennent en compte l'aspect spectral et local des images multispectrales. Les résultats obtenus afférentes à nos aux techniques que nous avons développées exposent qu'en avant l'importance d'utiliser conjointement ces aspects pour la segmentation d'images multispectrales. Bien que les détails de ces images soient complexes, les résultats de segmentation obtenus suite à différentes méthodes de segmentation montrent que les images traitées ont été correctement segmentées.

En réalité, pour évaluer les images du test utilisé, nous avons mis en place des critères d'évaluation. Nous avons exploité les critères de Levine et Nazif pour notre première méthode de segmentation basée sur l'optimisation multiobjectif et pour les deux autres, nous avons utilisé le critère d'évaluation de Borsotti.

Nous avons appliqué ces algorithmes aux images multispectrales. Les méthodes que nous avons développées ont permis de segmenter de manière adéquate les différentes images sélectionnées. Les régions ont été reproduites de manière adéquate par les techniques, ce qui démontre que nos méthodes sont plus efficaces que les techniques usuelles publiées dans la littérature, comme celle d'Otsu et K-means.

Afin d'optimiser davantage la segmentation des images multispectrales, il serait pertinent de :

CONCLUSION GENERALE

- Se pencher sur la possibilité d'élaborer une spécification automatique du seuil et du filtre adéquat ;
- Etudier davantage le processus de fusion des régions (utilisation d'autres distances colorimétriques).
- Automatiser tous les algorithmes développés au sein du laboratoire (Machine and Deep learning) ;
- S'aligner à la perception humaine via l'Intelligence Artificielle.

Liste des travaux de recherche

Articles publiés

Mechkouri S., Zennouhi R., [El Joumani S.](#), Masmoudi Lh., Gonzalez J., “Quantum segmentation approach for very high spatial resolution satellite image : application to Quickbird image”, Journal of Theoretical and Applied Information Technology, 62(2), 539-545, 2014

[El Joumani S.](#), Mechkouri S., Zennouhi R., El-Kadmiri O., Masmoudi Lh., “Segmentation method based on multiobjective optimization for very high spatial resolution satellite images”, EURASIP Journal on Image and Video Processing, SpringerOpen, 2016 (DOI 10.1186/s13640-016-0161-2)

Mechkouri S., [El Joumani S.](#), Masmoudi Lh., “Multi-Objective Optimization for Image Segmentation Based on the Tsallis and Rényi Entropies”, International Journal of Imaging and Robotics, 19(1), 31-44, 2019

Mechkouri S., [El Joumani S.](#), Zennouhi R., Masmoudi Lh., “Multi-Objective Optimization for Worldview Image Segmentation Based on the Entropies of Tsallis and Rényi”, International Journal of Advanced Trends in Computer Science and Engineering, SpringerOpen, 8(6), 2861-2872, 2019 (<https://doi.org/10.30534/ijatcse/2019/29862019>)

[El-Joumani S.](#), Mechkouri S., Zennouhi R., Masmoudi Lh., “Classification of

PUBLICATIONS

Satellite Image based on Quantum Approach and the Tsallis Entropy”, International Journal of Advanced Trends in Computer Science and Engineering, SpringerOpen, 9(1),610-617, 2020 (<https://doi.org/10.30534/ijatcse/2020/85912020>)

Mechkouri, S.E., [El Joumani S.](#), Zennouhi R., Masmoudi Lh., “Multi-Objective Optimization for Worldview Image Segmentation Funded on the Entropies of Tsallis and Rényi”, Multimedia Tools and Applications 79(41), 30637–30652, 2020. (<https://doi.org/10.1007/s11042-020-09572-4>)

[El Joumani S.](#), Mechkouri S., Zennouhi R., Masmoudi Lh., “Segmentation of satellite image based on quantum approach and the Havrda–Charvat entropy”, Multimedia Tools and Applications <https://doi.org/10.1007/s11042-023-17299-1>, 2023. (<https://link.springer.com/article/10.1007/s11042-023-17299-1>)

Bibliographie

Bibliographie

- [1] Christophe A., “Programme de l’enseignement spécifique et de spécialité de physique-chimie Classe terminale de la série scientifique ”, Bulletin officiel spécial n° 8, page 13, 13 octobre 2011

- [2] Chalençon S., Pop F., Cristea V., “Vision numérique et interaction”, L’université Paris VIII Vincennes - Saint-Denis , page 6, 2014

- [3] D. Ameisen 36es Assises de Pathologie, At Versailles, Volume : Bulletin de la Division Française de l’AIP n°57 - Juin 2013

- [4] C. Rabaud., Une nouvelle approche de mise en correspondance stéréoscopique dense par méthodes possibilistes, Université Montpellier II, 2005.

- [5] RC. Gonzalez, RE. Woods. (1993). Digital Image Processing. Reading, MA : Addison-Wesley
fransisco nivando bezerra :opérateurs topologique pour le traitement d’image en niveaux de gris. Thèse Doctorat,université marne la vallé,2001.

- [6] Fransisco N. B., Opérateurs topologique pour le traitement d’image en niveaux de gris, Thèse Doctorat, Université Marne la vallé,2001.

- [7] Marion A., Acquisition Et Visualisation Des Images. Eyrolles, 1997

BIBLIOGRAPHIE

- [8] Lezoray O., segmentation d'image couleur par morphologie mathématique et classification de données par réseaux de neurones : application à la classification de cellules en cytologie des séreuses. Thèse, Université de caen, France, 2000
- [9] Ouattara S. , Stratégies de segmentation d'images multi-composantes par analyse d'histogrammes multidimensionnels. Application à des images couleur de coupes histologiques de pommes. Thèse de doctorat, université d'Angers, 2009.
- [10] Lambert P., Études méthodologiques du filtrage et de la segmentation d'images multi-composantes, Habilitation à diriger des recherches en Electronique, Electrotechnique et Automatique, Université de SAVOIE, 2002.
- [11] Lillesand, T. and Kiefer, R., and Chipman, J., Remote sensing and image interpretation. John Wiley Sons. (Cited on pages 10 and 13.), 2014.
- [12] Landgrebe, D. and Signal theory methods in multispectral remote sensing, volume 29. John Wiley Sons. (Cited on page 10.), 2005.
- [13] D'après le site Web du Centre Canadien de Télédétection : <http://www.ccrs.nrcan.qc.ca>
- [14] Bayoudh M., THÈSE «Apprentissage de connaissances structurelles à partir d'images satellitaires et de données exogènes pour la cartographie dynamique de l'environnement Amazonien » Pour l'obtention du grade de Docteur, Décembre 2013.
- [15] Bulletin de l'Information Geographique Appliquée aux Activités de Recherche-Développement. BIG n 3 - Initiation à la Télédétection, 2008.
- [16] Tadjerouni K., Cours de Télédétection ; Centre National des Technologies Spatiales, Option petites échelles 2001 / 2002.
- [17] Girard Michel Claude, Girard Colette, Traitement de données de télédétection, 1999.

BIBLIOGRAPHIE

- [18] SOUDANI K., INTRODUCTION GENERALE A LA TELEDETECTION, Maître de Conférences Laboratoire Ecologie Systématique et Evolution, CNRS-Université Paris-Sud XI, 2007
- [19] Rees W. G., Physical Principles of Remote Sensing (Book), 2nd edition, Cambridge University Press, pp. 246-249, 2001
- [20] Troy Jensen, Armando Apan, Frank Young, Les Zeller and Ken Cleminson, “Assessing grain crop attributes using digital imagery acquired from a low-altitude remote controlled aircraft”, Spatial Sciences 2003
- [21] Lawrence J. Harman, Uma Shama, Kirk Dand, Brendan Kidwell, “Remote sensing and spatial information for transportation demand management (TDM) assessment”, Pecora 15/Land Satellite Information IV/ISPRS Commission I/FIEOS Conference Proceedings, 2002
- [22] CHIKR EL MEZOUAR M., Image fusion in satellite remote sensing. Thèse Université de Djillali Liabes de Sidi Bel-Abbes, Alger ? 2012
- [23] Matsuoka M. and Yamazaki F., “Use of Satellite SAR Intensity Imagery for Detecting Building Areas Damaged due to Earthquakes, Earthquake Spectra”, EERI 20(3) : 975-994, 2004
- [24] DiGiacomo Paul M., Libe Washburn, Benjamin Holt, Burton H. Jones, “Coastal pollution hazards in southern California observed by SAR imagery : stormwater plumes, wastewater plumes, and natural hydrocarbon seeps”, Marine Pollution Bulletin 49 :1013–1024, 2004
- [25] Mathiew D. B., “Synthetic Aperture Radar in the Role of Surveillance”, GEC Review 13(3), 1998

BIBLIOGRAPHIE

- [26] Thomasson A., Mondelain D., Ménard T., Nominé M., Godet Y., Wolf J., “Air pollution mapping using all solid- state LIDAR systems”, C.R. Academy of Science 7(IV) : 923-929, 2001
- [27] Ulrich P., “Laser remote sensing”, Trends in Analytical chemistry 17(8+9), 491-500, 1998
- [28] As-syakur A.R.; Osawa, T.; Adnyana, I.W.S. Medium Spatial Resolution Satellite Imagery to Estimate Gross Primary Production in an Urban Area. Remote Sens., 2, 1496-1507, 2010.
- [29] Weng, Q., Hu, X. , Medium spatial resolution satellite imagery for estimating and mapping urban impervious surfaces using LSMA and ANN. IEEE Transactions on Geoscience and Remote Sensing, 46(8), 2397-2406, 2008.
- [30] Petri, R.; Ranchin, T. « Potentialités des nouveaux capteurs à très haute résolution spatiale pour l'extraction des réseaux de rues urbains ». Revue internationale de Géomatique. 14, pp. 485-504, 2004.
- [31] Vasques A. R., Volpe L.L. and Lombardo M.A., « Multitemporal analysis to identify brownfields redevelopment dynamic by high resolution satellite imagery in Sao Paulo-Brasil », Proceeding of the 4th WSEAS International Conference on REMOTE SENSING (REMOTE'08) pp 130-135, venice italy November 21-23, 2008.
- [32] Bloch I., Tupin F. et Manzanera A., TERI : Traitement et reconnaissance d'images, Cours Master 2 IAD.
- [33] S. Zucker, Region growing Childhood and adolescence. Computer Graphics and Image Dans Processing 5, pp. 382-399, 1976.
- [34] A. OUARDIA, Segmentation d'images par seuillage d'histogrammes bidimensionnels, MEMOIRE DE MAGISTER en Automatique, Université Mouloud Mammeri de Tizi-

BIBLIOGRAPHIE

- Ouzou Alger, 2011.
- [35] R.C. Gonzalez and R.E. Woods. Digital image processing. Addition-Wesley, Reading, MA 1992.
- [36] Pavlidis and Y-T. Liow . « integrating region growing and edge detection » IEEE Trans. Pattern analysis and machine intelligence. Vol. 12, n°3, pp. 225-23, 1990.
- [37] R. Haralick and L. Shapiro. Image segmentation techniques. Computer Vision Graphics Image Processing, vol 29, pp 100-132, 1985.
- [38] R. Gonzalez and R. Woods. Digital image processing. Addition-Wesley, Reading, MA 1993.
- [39] Ohlander, K. Price, and D. R. reddy “picture segmentation using recursive region splitting method” computer graphics and image processing, vol, 8, pp. 313-333, 1979.
- [40] C. KERMAD, K. CHEHDI, and Claude Cariou. Segmentation d’images par multi-seuillage et fusion de régions labellisées minimisant un critère de similarité. In 15ème Colloque sur le traitement du signal et des images, FRA, 1995. GRETSI, Groupe d’Etudes du Traitement du Signal et des Images, 1995.
- [41] Basarab Matei. Methodes multiresolutions non-lineaires. Applications au traitement d’image. PhD thesis, Université Pierre et Marie Curie-Paris VI, 2002.
- [42] S.L. Horowitz and T. Pavlidis. Picture segmentation by tree transversal algorithm. Journal of the association for computing machinery. Vol. 23, n°2, pp. 368-388. 1976.
- [43] J.R. Beveridge, J.G. Riffith, R.R. Kohler, A.R. Hanson et E.M. Riseman. Segmenting images using localized histograms and region merging IJC. Vol. 2, pp 311-347, 1986.

BIBLIOGRAPHIE

- [44] K.C. Strasters and J.J. Gerbands. Three-dimensional image segmentation using a split, merge and group approach, *Pattern Recognition letters*, vol. 12, n°3, pp. 307-325, 1991.
- [45] Hult, R., Grey-level morphology combined with an artificial neural networks approach for multimodal segmentation of the hippocampus. *International Conference on Image Analysis and Processing*, PP. 277–282, 2003.
- [46] A. Clement, and B. Vigouroux. (2003). Unsupervised segmentation of scenes containing vegetation (Forsythia) and soil by hierarchical analysis of bi-dimensional histograms, *Pattern Recognition Letters*, 24, 1951–1957.
- [47] M. Wolfel, H.K. Ekenel. (2005). Feature Weighted Mahalanobis Distance : Improved Robustness for Gaussian Classifiers. *13th European Signal Processing Conference (EUSIPCO)*, Antalya, Turkey.
- [48] Kabir Y., *Cours de traitement d'image*, 2004.
- [49] N. MERZOUGUI, Un algorithme évolutionnaire pour la segmentation d'images basé sur le diagramme de Voronoï, *Mémoire du diplôme de MAGISTER EN INFORMATIQUE, UNIVERSITE KASDI MERBAH-OUARGLA, Alger*, 2012.
- [50] M. MELIANI, Segmentation d'Image par Coopération Régions-Contours, *Mémoire du diplôme de MAGISTER EN INFORMATIQUE, Ecole nationale Supérieure en Informatique Oued-Smar Alger*, 2012.
- [51] J. Modestino, R. Fries. Edge detection in noisy images using recursive digital filters. *Comp. Graph. and Image Proc.*, 409–433, 1977.
- [52] V. Torre, T. Poggio. On edge detection. *IEEE Pattern Analysis and Machine Intelligence*, 8, 147–153, 1986.

BIBLIOGRAPHIE

- [53] I. Sobel. Neighbourhood coding of binary images for fast contour following and general array binary processing. *Computer Graphics and Image Processing*, vol. 8, pp. 127-135, 1978.
- [54] L. G. Roberts. Machine perception of three dimensional solids. In J. T. and al. Tippet, editor, *Optical and Electro-optical Information Processing*, pp. 159-197. MIT Press, Cambridge, 1965.
- [55] J. M. S. Prewitt. Object enhancement and extraction. In *PPP70*, pp. 75-149, 1970.
- [56] D. Marr, E. Hildreth. Theory of edge detection. In *Proc. Royal Soc. London*, volume 207 of B, 187–217, 1980.
- [57] J. Serra, *Image analysis and mathematical morphology*, Academic Press, New York, 1982.
- [58] A. Coutant. ‘La méthode des contours actifs en traitement des images’, mémoire pour l’examen probatoire en Calcul Scientifique, 2005.
- [59] J. Clark, Authenticating edges produced by zerocrossing algorithms, *IEEE Trans. Pattern Anal. Machine Intell.*, vol. 12, n°8, 830–841, 1989.
- [60] SELMAOUI, N., *Traitement Analyse d’images*, Licence Informatique. www.tice.univ-nc.nc/selmaoui/Teach/LMD/lmd.html, 2005.
- [61] J. Canny, A Computational Approach to Edge Detection, *IEEE Transactions on Pattern Analysis and Machine Intelligence*, Vol 8, No. 6, Nov 1986.
- [62] R. Deriche, Using Canny’s criteria to derive a recursively implemented optimal edge detector, *International Journal of Computer Vision*, pp. 167-187, 1987.

BIBLIOGRAPHIE

- [63] Georges Koepfler. 'Traitement du signal et des images', Notes de cours (formation continue), Université de Paris 9 Dauphine (1997-2002), 2003.
- [64] J. Shen, S. Castan. An optimal linear operator for step edge detection. Graphical Model and Image Processing, 54 (2), p. 112-133. Mars 1992.
- [65] Kass, M., Witkin, A. et Terzopoulos, D., Snakes : active contour models. International Journal of Computer Vision, 1(4) : 321-331, 1987.
- [66] D. Azerradj et D. Kessoum. "Application des contours actifs géodésiques pour la segmentation de la vidéo" PFE. INI. 2006/2007, Mémoire de fin d'études, INI 2007.
- [67] M.F Hueckel An operator which locates edges in digitized pictures, J. Ass.Comput. Mach, vol. 18, n^o 1, pp. 113-125, 1971.
- [68] K. Haris, S. Efstratiadis, N.Magiaveras et A. Katsaggelos. Hybrid image segmentation using watersheds and fast region merging. IEEE Trans.Image. Processing, vol.7, pp 1684-1699, 1998.
- [69] Acharya T. A., "Image Processing, Principles and Applications" chapitre 7. "A Wiley-Interscience Publication", 2005.
- [70] I. Sebari et Dong-Chen HE « Les approches de segmentation d'image par coopération régions-contours». Centre d'applications et de recherches en télédétection (CARTEL), Département de géomatique appliquée, Université de Sherbrooke, 2500, boulevard de l'Université, Sherbrooke (Québec), Canada J1K 2R1Revue Télédétection, vol. 7, n° 1-2-3-4, p. 499-506, 2007.
- [71] Priyanka G. Kumbhar, 2 Prof. Sushilkumar N. Holambe," A Review of Image Thresholding Techniques", International Journal of Advanced Research in Computer Science and Software Engineering , Volume 5, Issue 6, June 2015.

BIBLIOGRAPHIE

- [72] Huang Z.K. and Chu K. W., A new threshlding method based on Gaussian mixture model. Model, Appl. Ms th. Compt, doi : 10.1016/j ;amc.2008.05.130, 2008.
- [73] A. P. Dempster, N. M. Laird, D. B. Rubin, Maximum likelihood from incomplete data via the EM algorithm. Journal of the Royal Statistical Society. vol. 39, n°1, pp.1-38, 1977.
- [74] Sahoo, P. K., et al., A survey of thresholding techniques. Computer Vision, Graphics, and Image Processing, Vol. 41, pp. 233-260, 1988.
- [75] J. P. Cocquerez and S.Philipp, Analyse d'images et segmentation. Masson, 1995.
- [76] R. C. Gonzalez and R. E. Woods, Digital image processing. Pearson Prentice Hall, 2002.
- [77] N. Bhargava, A. kumawat and R. Bhargava, Threshold and binarization for document image analysis using otsu's Algorithm, International Journal of Computer Trends and Technology (IJCTT) – volume 17 Number 5 Nov 2014.
- [78] N. Kapur, P.K. Sahoo, and A.K.C.Wong, "A New Method for Gray Level Picture Thresholding Using the Entropy of the Histogram," Computer Vision, Graphics and Image Processing, vol. 29, pp. 273-285, 1985.
- [79] MacQueen, Some methods for classification and analysis of multivariate observations. Dans Proceeding 5th Berkeley Symp., pp 281–297 1967.
- [80] A. Nakib, Conception de métaheuristiques d'optimisation pour la segmentation d'images. Application à des images biomédicales, Thèse de doctorat, Université de Paris 12-Val de Marne, 2007.
- [81] A. Nakib, Conception de métaheuristiques d'optimisation pour la segmentation d'images. Application à des images biomédicales, Thèse de doctorat, Université de Paris 12-Val de Marne, 2007.

BIBLIOGRAPHIE

- [82] N. Monmarché. Algorithmes des fourmis artificielles : applications à la classification et à l'optimisation, Thèse de doctorat, Université de Tours. 2000.
- [83] W. Niblack, Introduction to digital image processing. Prentice Hall, 1986.
- [84] J. Sauvola, M. Pietikainen , “Adaptive document image binarization”. Pattern Recognition, 33 pp.225-236, 2000.
- [85] M. Kamel and A. Zhao. Extraction of binary character/ Graphics images from greyscale document images. Graphical Models and Image Processing, vol. 55, No. 3, pp. 203-217, 1993.
- [86] T. Kohonen Self-Organization and Associative Memory Springer-Verlag, 1984.
- [87] S. Thiria, Y. Lechevallier, O. Gascuel and S. Canu, Statistique et Méthodes Neuronales, Dunod, Paris, 1997.
- [88] H. Digabel et C. Lantuéjoul. Iterative algorithms Dans J. L. Chermant, éditeur, Proc. 2nd European Symp. Quantitative Analysis of Microstructures in Material Science, Biology and Medicine, Stuttgart, Riederer Verlag. pp.85-99, 1978.
- [89] L. Najman, and M. Couprie, Watershed algorithms and contrast preservation. Discrete geometry for computer imagery., vol. 2886, pp. 62-71. 2003.
- [90] A Nakib, H Oulhadj, P Siarry, Image histogram thresholding based on multiobjective optimization. Signal Process. 87, 2516–2534 (2007).
- [91] Barra V., Evaluation of MR-brain-volumetry methods. University of Clermont-Ferrand, ISIMA, 2007.

BIBLIOGRAPHIE

- [92] Spinu, C. . Une approche multi-agents pour la segmentation d'images associant et évaluation. Thèse de Doctorat de l'Université J. Fourier,, Grenoble. (1997.)
- [93] Sébastien Chabrier, « Contribution à l'évaluation de performances en segmentation d'images. », Thèse de Doctorat, à l'Université d'Orléans, 2005.
- [94] D. M. Chau, Évaluation de la segmentation d'images, Institut de la francophonie pour l'informatique (IFI), Hanoï, janvier 2007.
- [95] J.-P. Cocquerez et S. Philipp, Analyse d'Images : filtrage et segmentation. Masson 1995.
- [96] GOUMEIDANE A. B., Segmentation et évaluation des images segmentées, thèse pour l'obtention du Diplôme de Doctorat, UNIVERSITE MENTOURI-CONSTANTINE, Alger, 2010.
- [97] F. Argenti et L. Alparone. Speckle removal from SAR images in the undecimated wavelet domain. IEEE Transactions on Geoscience and Remote Sensing, 40 : 2363–2374, 2002.
- [98] C. Rosenberger, Contribution à l'évaluation d'algorithmes de traitement d'images, Thèse de doctorat, UNIVERSITÉ D'ORLÉANS, 2006.
- [99] W. Pratt, O. D. Faugeras, and A. Gagalowicz. Visual discrimination of stochastic texture fields. IEEE Transactions on Systems, Man, and Cybernetics, 8(11) :796–804, 1978.
- [100] Spinu, C., Une approche multi-agents pour la segmentation d'images associant et évaluation. Thèse de Doctorat de l'Université J. Fourier,, Grenoble, (1997.)
- [101] T. Peli and D. Malah. A study of edge detection algorithms. Computer Graphics and Image Processing, 20 :1–21, 1982.

BIBLIOGRAPHIE

- [102] L. Vinet. Segmentation et mise en correspondance de régions de paires d'images stéréoscopiques Thèse de Doctorat de l'université de Paris IX Dauphine, 1991.
- [103] YASNOFF W. A., GALBRAITH W. , BACUS J. W., Error measures for objective assessment of scene segmentation algorithms, AQC, 1, p. 107-121, 1979.
- [104] D. MARTIN. « An empirical approach to grouping and segmentation ». Thèse de doctorat, University of California, Berkeley : USA, 2002.
- [105] C. E. Liedtke, T. Gahm, F. Kappei, and B. Aeikens. "Segmentation of microscopic cell scenes". AQCH, 9 :197–211, 1987.
- [106] K. Cho and P. Meer. "Image segmentation from consensus information". Computer-Vision and Image Understanding (CVIU), 68 :72–89, 1997.
- [107] N. Voisine. "Approche adaptative de coopération hiérarchique de méthodes de segmentation : application aux images multicomposantes ". PhD thesis, Université de Rennes I, 2002.
- [108] A.B. Goumeidane, M. Khamadja, and N. Nacereddine, "Bayesian Pressure Snake for Weld Defect Detection" J. Blanc-Talon et al. (Eds.) : ACIVS 2009, LNCS 5807, pp. 309–319, 2009. © Springer-Verlag Berlin Heidelberg 2009.
- [109] L. Kitchen et A. Rosenfeld. Scene analysis using regionbased constraint filtering. Pattern Recognition, 17(2) : 189–203, 1984.
- [110] M. D. Levine et Ahmed M. Nazif. Dynamic Measurement of Computer Generated Image Segmentations. IEEE Transaction on Pattern Analysis and Machine intelligence, PAMI-7(2) : 155–164, March 1985.

BIBLIOGRAPHIE

- [111] J. H. Han and T. Y. Kim. Ambiguity distance : an edge evaluation measure using fuzziness of edges. *Fuzzy Sets and Systems*, 126 :311–324, 2002.
- [112] M. Borsotti, P. Campadelli, et R. Schettini. « Quantitative evaluation of color image segmentation results ». *Pattern Recognition Letters*, 19 : 741–747, 1998.
- [113] C. Rosenberger, Mise en oeuvre d’un syst’eme adaptatif de segmentation d’images, Ph.D. thesis, Universit’e de Rennes 1, Rennes, France, 1999.
- [114] [4]. El Joumani S., Mechkouri S. E., Zennouhi R., El Kadmiri O., Masmoudi L., (2017). Segmentation method based on multiobjective optimization for very high spatial resolution satellite images, *EURASIP Journal on Image and Video Processing*, DOI 10.1186/s13640-016-0161-2.
- [115] R Zennouhi, L Masmoudi, A new 2D-histogram scheme for colour image segmentation. *Imaging Sci. J.* 57, 260–365 (2009).
- [116] S Mechkouri, R Zennouhi, L Masmoudi, J Gonzalez, Colour image segmentation using hierarchical analysis of 2D-histograms : application to urban land cover and land use classification. *Geo Observateur* 18,43–57 (2010).
- [117] Mechkouri S. EL Joumani S., Zennouhi R., Masmoudi Lh. and Gonzalez J. G., Quantum segmentation approach for very high spatial resolution satellite image : application to QuickBird image, *JOURNAL OF THEORETICAL AND APPLIED INFORMATION TECHNOLOGY*, April 2014, vol.62 n° 2, pp. 539-545. .
- [118] Lien de site de la base de données des images synthétiques : <http://pages.upf.pf/Sebastien.Chabrier/ressources.php>.
- [119] Cheng H.D., Jiang X.H., Sun Y., Wang J., image segmentation advances and prospects”, *Pattern Recognition*, 34(6), 2259-2281, 2001.

BIBLIOGRAPHIE

- [120] Cheng H.D., Jiang X.H., Sun Y., Wang J., image segmentation advances and prospects”, Pattern Recognition, 34(6), 2259-2281, 2001.
- [121] Zennouhi R.; Masmoudi Lh. and El Ansari M., RGB Image Segmentation Using Hierarchical Analysis of 2D-Histograms : Application to Menthe Plant. International Conference : Sciences of Electronic; Technologies of Information and Telecommunications; 2009 – TUNISI.
- [122] Tsallis, C., Possible generalization of BoltzmannGibbs statistics. Journal of Statistical Physics, (1988), 52, 479-487.
- [123] Parvan, A.S., Critique of multinomial coefficients method for evaluating Tsallis and Rényi entropies. Physica A 2010, 389(24), 5645–5649.
- [124] Tsallis, C. Non additive Entropy and Non extensive Statistical Mechanics - an Overview after 20 Years. Braz. J. Phys, 2009, 39, 337-356.
- [125] Vincent L. and Soille P.; Watersheds in digital spaces : An efficient algorithm based on immersion simulation, IEEE Trans; Pattern Anal; Mach Intell, 1991, 13 (6), pp. 583–598.
- [126] Portes de Albuquerque M., Esquef I.A., Gesualdi Mello A.R., Image thresholding using Tsallis entropy. Patt. Recog. Lett., 2004, 25(9), 1059–1065.
- [127] Havrda, J., Charvát, F., (1967). Quantification Methods of Classification Processes : Concept of Structural Alpha-Entropy. Kybernetika (Prague) 3, 95-100.