

THESE

En vue de l'obtention du : **DOCTORAT**

Structure de Recherche : Laboratoire Conception et Systèmes (Electronique, Signaux et informatique)

Discipline : Sciences de l'ingénieur

Spécialité : Electronique et traitement d'Images

Présentée et soutenue le : 23/10/2021 par :

Salah Eddine MECHKOURI

Nouvelles méthodes de segmentation des images satellitaires à très hautes résolution : Application à l'utilisation et à la couverture du sol

JURY

Ilias KACIMI	PES, Université Mohammed V, Faculté des Sciences - Rabat	Président
Mohamed SBIHI	PES, Université Mohammed V, Ecole Supérieure de Technologies - Salé	Rapporteur/Examineur
Nouredine ZAHID	PES, Université Mohammed V, Faculté des Sciences - Rabat	Rapporteur/Examineur
Majid HADRI	PES, Université Mohammed V, Faculté des Sciences - Rabat	Rapporteur/Examineur
Abderrahmane HAJRAOUI	PES, Université Abdelmalek ESSAADI, Faculté des Sciences - Tétouan	Rapporteur/Examineur
Hassane ROUKHE	PES, Institut Supérieur des Métiers de l'Audiovisuel et du Cinéma - ISMAC - Rabat	Rapporteur/Examineur
Lhoussaine MASMOUDI	PES, Université Mohammed V, Faculté des Sciences - Rabat	Directeur de Thèse

Année Universitaire : 2020/2021

Nouvelles méthodes de segmentation des images
satellitaires à très hautes résolution : Application
à l'utilisation et à la couverture du sol

Salah Eddine Mechkouri

23 octobre 2021

Remerciements

D'abord, cette thèse a été élaborée au sein du laboratoire Conception et Systèmes (Électronique, Signaux et Informatique) (LCS) à la faculté des Sciences de l'Université Mohammed V de Rabat.

Mes remerciements s'adressent aux personnes qui ont contribué à la concrétisation de ce travail de thèse de doctorat.

Mes sincères remerciements vont aux personnes qui ont cru en moi. Je tiens à remercier Monsieur Lhoussaine MASMOUDI, professeur de l'Enseignement Supérieur à l'Université Mohammed V de Rabat et directeur de thèse qui m'a encadré tout au long des années de thèse et qui m'a permis d'approfondir la compréhension des divers aspects de mon sujet. Je le salue pour m'avoir permis une large marge de liberté pour mener à bien ma recherche.

Monsieur Ilias KACIMI, Professeur de l'enseignement supérieur à l'Université Mohammed V de Rabat d'avoir accepté de présider le jury de soutenance, qu'il trouve ici l'expression de mes sincères remerciements.

Mes remerciements les plus sincères à Monsieur Mohamed SBIHI, Professeur de l'enseignement supérieur à l'École Supérieure de Technologie de Salé Université Mohammed V de Rabat qui a accepté de faire partie du jury de soutenance.

Mes sincères remerciements adressés à Monsieur Nouredine ZAHID, Professeur de l'enseignement supérieur à l'Université Mohammed V de Rabat qui a accepté de faire partie du jury de soutenance.

Mes remerciements vont également à Monsieur Majid HADRI, Professeur de l'enseignement supérieur à l'Université Mohammed V de Rabat qui a accepté de faire partie du jury de soutenance.

Je remercie fortement Monsieur Abderrahmane HAJRAOUI, Professeur de l'enseignement supérieur à l'Université Abdelmalek ESSAADI de Tetouan qui a accepté de faire partie du jury de soutenance.

Monsieur Hassane ROUKHE, Enseignement chercheur à Institut Supérieur des Métiers de l'Audiovisuel et du Cinéma - ISMAC Rabat, a bien voulu consacrer du temps à examiner le présent travail en prenant part au jury. Qu'il reçoive ici mes remerciements les plus chaleureux.

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

Je remercie ma famille, en particulier mon épouse et ma fille pour l'amour qu'elles m'ont porté durant toutes les années de recherche, J'espère qu'elles trouvent dans ce modeste travail la récompense du manque de mon amour et tendresse au cours de la réalisation de cette thèse.

Je voudrai aussi exprimer ma gratitude à ma mère, mes frères et mes soeurs qui m'ont manifesté leur soutien et m'ont constamment témoigné leur amour et leur dévotion.

Enfin, je remercie les membres de jury pour l'attention qu'ils accorderont à cette thèse.

Résumé

Ce travail de recherche entre dans le cadre du développement des techniques de segmentation, qui sont jusqu'à présent destinées, dans la majorité des méthodes de segmentation développées, aux images en niveaux de gris. Certains travaux récents, ont été consacrés à les généraliser aux images multispectrales.

Dans cette thèse, nous présenterons une amélioration de la méthode de segmentation hiérarchique des histogrammes 2D appliquée aux images du satellite QuickBird. L'approche de base que nous avons amélioré utilise, généralement, des stratégies de segmentation qui ne prennent pas en compte les corrélations spectrales et spatiales existantes entre les pixels de l'image. Pour pallier à cet inconvénient, tout en restant dans le même concept de l'analyse hiérarchique des histogrammes 2D, nous avons élaboré deux techniques de segmentation qui permettront de détecter les régions d'intérêt dans des images multispectrales :

- La première est basée sur la physique quantique par la résolution de la fonction d'onde appliquée aux images multispectrales.

- La seconde, est fondée sur la fonction d'optimisation multiobjectif appliquée aux images panchromatiques.

Nous avons appliqué ces techniques à des images synthétiques texturées en couleur et en niveau de gris. Les deux méthodes développées (fonction d'onde et optimisation multiobjectif), ont rapporté des cartes de segmentation compactes et cohérentes.

En effet, pour évaluer nos méthodes de segmentation d'images multispectrales du satellite QuickBird, nous avons utilisé les critères suivants :

- Pour le cas de la fonction d'onde nous avons utilisé le coefficient d'évaluation de *Borsotti*,
- Pour la segmentation d'optimisation multiobjectif nous nous sommes basés sur les critères de *Levine et Nazif*.

Quant aux résultats de segmentation des images multispectrales obtenus par ces deux méthodes, nous en sommes très satisfaits ; la couverture et l'utilisation du sol ont été correctement détectées et identifiées et les régions ont été correctement reproduites par les deux techniques.

Mots-clés :

Images multispectrales, histogramme 2D, segmentation et classification, fonction d'onde, Optimisation multiobjectif et entropie.

Abstract

This study is part of the development of segmentation techniques for satellite image with very high spatial resolution, which are constantly increasing.

The objective of this work is to improve the method of hierarchical segmentation of 2D histograms applied to satellite images. The basic approach, that we improved, has used, generally, segmentation strategies, which did not take into account, the spectral and spatial correlations existing between the pixels of the image. Within the same concept of hierarchical analysis of 2D histograms, two segmentation techniques have been developed :

- The first one , is based on quantum physics through the resolution of the wave function applied to multispectral images.
- The second one, is based on the multiobjective optimization function applied to panchromatic images and worldview images.

These techniques have been applied to textured synthetic images in colour and grayscale. The two methods developed (wave function

and multiobjective optimization) have produced compact and coherent segmentation maps.

In addition, to evaluate our methods of segmenting satellite images, evaluation criteria were chosen :

- On the one hand, the Borsotti coefficient for the wave function.
- On the other hand, the booth Levine & Nazif criteria and the Mean Square Error criteria for the multiobjective optimization functions.

As for the segmentation results of very high spatial resolution satellite images obtained by these two methods, they have been satisfactory. Coverage and land use were correctly detected and identified and the regions were correctly reproduced by both techniques.

Keywords :

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

Table des Matières

Table des matières

Remerciements	i
Résumé	v
Abstract	viii
Table des Matières	xi
Abréviations	xx
Symboles	xxii
Introduction	1
1 Les images multispectrales	7
1.1 Introduction	8
1.2 La télédétection spatiale	9
1.2.1 La source d'énergie	10
1.2.2 Les interactions du rayonnement avec l'atmosphère . . .	10
1.2.3 Les interactions du rayonnement avec la surface terrestre	10
1.2.4 L'enregistrement du signal par le capteur satellitaire . .	10
1.2.5 La transmission et la réception des données	11
1.3 Le rayonnement électromagnétique	11

TABLE DES MATIÈRES

1.3.1	Le domaine du visible	12
1.3.2	L'infrarouge	13
1.3.3	Les hyperfréquences	14
1.4	Le rayonnement et l'atmosphère	14
1.4.1	Absorption et émission atmosphérique	16
1.4.2	Diffusion atmosphérique	16
1.5	Le rayonnement et la matière	18
1.5.1	Les interactions entre le rayonnement et la matière	18
1.5.2	Les signatures spectrales des principales surfaces naturelles	19
1.6	Compositions colorées à partir d'images multispectrales	21
1.6.1	Images multispectrales	21
1.6.2	Compositions colorées à partir d'images multispectrales	22
1.7	Discussion	25
2	Segmentation et Classification des Images Multispectrales	27
2.1	Introduction	28
2.2	Couverture et utilisation du sol	29
2.3	Les principes de la segmentation	30
2.4	Les indices visuels	32
2.5	Le seuillage	34
2.5.1	Principes du seuillage	34
2.5.2	La détection de vallées	34
2.5.3	La minimisation de variance	37
2.5.4	Seuillage entropique	38
2.5.5	Méthode du pourcentage	39
2.5.6	Maximisation du contraste	40
2.5.7	Bilan sur le seuillage	41
2.6	La recherche de régions	42
2.6.1	Le modèle de région	42

TABLE DES MATIÈRES

2.6.2	La croissance de région	43
2.7	L'approche de la classification	44
2.7.1	Introduction	44
2.7.2	Les méthodes de classification	45
2.8	Classification non supervisée par analyse hiérarchique d'histo- gramme 2D	46
2.8.1	Principe	47
2.8.2	Expérimentations	49
2.9	Conclusion	50
3	Segmentation d'images à l'aide d'analyse hiérarchique des his- togrammes 2D	51
3.1	Introduction	52
3.2	Méthodes et matériels	54
3.2.1	Traitement Numérique des images	54
3.2.2	Les données de l'image QuickBird	55
3.3	Méthode de classification	56
3.3.1	Construction de l'histogramme 2D	56
3.3.2	Analyse hiérarchique de l'histogramme 2D	58
3.3.3	Distance	59
3.4	Résultats et discussion	61
3.5	Conclusions	66
4	Segmentation d'images Satellites de très haute résolution spa- tiale	67
4.1	Introduction	68
4.2	Description de la méthode de la fonction d'onde	71
4.2.1	Modèle pour la Particule	72
4.2.2	Modèle pour l'Image Satellite	73

TABLE DES MATIÈRES

4.2.3	Méthode de classification	75
4.2.4	Fonction d'évaluation de Borsotti $Q(I)$	75
4.2.5	Données d'images multispectrales	77
4.2.6	Résultats et discussion	77
4.3	Description de la méthode d'optimisation multiobjectifs	83
4.3.1	Le critère de la variance intra-classe	84
4.3.2	Le critère de la probabilité d'erreur globale	85
4.3.3	Le critère de l'Entropie Totale	86
4.3.4	Le critère d'Entropie de Tsallis	87
4.3.5	Le critère d'Entropie de Rényi	89
4.3.6	La Fonction objectif -Objective function-	91
4.3.7	Données d'Images Satellites	94
4.3.8	Critères d'évaluation utilisés	97
4.3.9	Évaluation des fonctions d'optimisation multiobjectifs développées	101
4.3.10	Résultats et discussion	104
4.4	Conclusion	116
	Conclusion générale	120
	Bibliographie	123
	Publications	133
	Annexes	137

Liste des tableaux

1.1	Longueurs d'onde et fréquences des couleurs du spectre visible.	13
1.2	Caractéristiques des bandes multispectrales de l'image Quick-Bird MS.	22
4.1	Valeurs du Coefficient Q pour ψ et $ \psi ^2$ -Image aux niveaux de gris-.	80
4.2	Valeurs du Coefficient Q pour ψ , $ \psi ^2$ dans l'espace RGB . . .	80
4.3	Caractéristiques de l'image Panchromatique (QuickBird 2). . .	95
4.4	Caractéristiques de l'image Panchromatique (Worldview). . . .	97
4.5	Les valeurs des critères d'évaluation de Levine et Nazif des deux fonctions d'optimisation multiobjectifs (MOBJ1 et MOBJ2). . .	102
4.6	Les valeurs des critères d'évaluation des fonctions d'optimisation multiobjectifs (MOBJ2 et MOBJ3).	103
4.7	Valeurs d'évaluation du critère de Levine et Nazif pour diverses méthodes (Image Synthétiques).	108
4.8	Valeurs d'évaluation du critère de Levine et Nazif pour diverses méthodes (Images Panchromatiques).	109
4.9	Valeurs d'évaluation des Image Synthétiques	111
4.10	Valeurs d'évaluation des Images sentinel	114

Table des figures

1.1	Processus de la télédétection [6].	9
1.2	Spectre électromagnétique [6].	11
1.3	Domaine du visible du spectre électromagnétique [6].	12
1.4	Spectre des corps noir à 5800K et à 288K , températures d'émission du soleil (bleu) et de la terre (rouge) [6].	15
1.5	Interaction du rayonnement électromagnétique avec la matière [6].	19
1.6	Signature spectrale des surfaces naturelles dans le domaine du visible, du proche infra rouge et de l'infrarouge moyen [6].	20
1.7	® Digital Globe : Zone d'étude –QuickBird RGB Image cou- leur composite réalisée à partir des bandes 321, acquise le 15 juin 2006 à 12h -.	23
1.8	® Digital Globe : Zone d'étude : Image Panchromatique acquise le 15 juin 2006 à 12h.	24
1.9	Image QuickBird composite en fausses couleurs réalisée à partir des bandes IR G B 421.	25
2.1	Exemple d'image et d'histogramme bi-modale [24].	35
2.2	Exemple de seuillage en 4 classes par histogramme [24].	36
2.3	Histogramme bi-modal dont les deux pics principaux présentent des maxima locaux non pertinents pour la segmentation [24].	36

TABLE DES FIGURES

2.4	Classification dans l'espace RGB	45
2.5	Exemple de décomposition hiérarchique [31].	48
3.1	® Digital Globe : Zone d'intérêt de l'image RGB	56
3.2	Un exemple de décomposition hiérarchique [31].	58
3.3	Histogrammes RG et HV de l'image synthétique dans les espaces RGB et HSV	63
3.4	Image QuickBird RGB	64
3.5	Résultat d'Histogramme RG	64
3.6	Histogramme 2D utilisant l'espace HSV	65
3.7	Vue de dessus de l'histogramme 2D.	65
4.1	Modèle de la Particule.	72
4.2	Modèle d'image satellite.	74
4.3	–QuickBird RGB Image– Zone d'étude sélectionnée.	77
4.4	Image des carrés synthétiques (465 X 386).	78
4.5	Image aux niveaux de gris.	79
4.6	Image segmentée utilisant la méthode proposée.	79
4.7	Image couleur originale RGB	81
4.8	Image Segmentée utilisant l'histogramme RB dans l'espace RGB	81
4.9	Image segmentée utilisant l'histogramme RG construit par ψ	82
4.10	Image segmentée utilisant l'histogramme RB construit par $ \psi ^2$	82
4.11	® Digital Globe : Zone d'étude de l'image Panchromatique QuickBird	95
4.12	® Digital Globe : Zone d'étude de l'image Panchromatique Worldview	96
4.13	Segmentation d'images par les deux fonctions d'optimisation multiobjectifs.	101

TABLE DES FIGURES

4.14	Segmentation d'images par MObj2 et MObj3.	104
4.15	Résultats de la segmentation des images synthétiques.	107
4.16	Résultats de la segmentation des images Panchromatiques. . .	107
4.17	Résultats de la segmentation des images synthétiques	113
4.18	Résultats de la segmentation des images sentinel	116

Abréviations

LCS	Laboratoire Conception et Systèmes (Électronique, Signaux et Informatique)
2D	Deux Dimensions
MS	Multiple-Spectrales
<i>IR</i>	Infra Red (Infra-Rouge)
<i>RGB</i>	Red Green Blue (Rouge, Vert et Bleu)
<i>HSV</i>	Hue Saturation Value (Espace colorimétrique Teinte, Saturation et Luminosité)
<i>Min</i>	Minimum
<i>Max</i>	Maximum
<i>MVar(I)</i>	Le critère de la variance intra-classe
<i>Q(I)</i>	La fonction d'évaluation de Borsotti
MOBJ1	La fonction d'optimisation multiobjectif appliquée aux images à deux seuils (images médicales) par Nakib
MOBJ2	La fonction d'optimisation multiobjectif modifiée par l'introdu- ction 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
MSE	Moyenne d'erreur quadratique

Symboles

K_B	La constante de Boltzmann
ν	La fréquence du rayonnement
h	La constante de Planck
α	Le coefficient d'absorption
ρ	Le coefficient de réflexion
τ	Le coefficient de transmission
ϕ	La longitude
λ	La latitude
m	Le metre unité de mesure des distances
nm	Le nano-metre unité de mesure des longueurs d'onde
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 constant 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
r, g et b	Les valeurs de pixel respectivement dans le plan $\mathbf{R}$, $\mathbf{G}$ et $\mathbf{B}$ de l'image
p_{max} et p_{min}	Respectivement la valeur minimale et la valeur maximale de $\mathbf{P}$
$Q(I)$	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 $n^o i : C_i$
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 $n^o i$
D_i	L'ensemble des niveaux de gris j associés à la classe C_i
p_j	La probabilité a posteriori 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
K_i	Les pics correspondants aux feuilles encerclées sur la droite de la figure 3.2

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 : $0 < T1 < T2 < ... < Td - 1 < 255$
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 $R = R_1, ..., R_{NR}$ ayant NR régions
$Card(I)$	Correspond au nombre de pixels de l'image I
$g_I(s)$	Correspond à l'intensité du niveau de gris du pixel s de l'image I

pdf	Gaussienne fonction de densité de probabilité
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
$\bar{g}_I(R_k)$	C'est 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
S_q	Entropie de Tsallis
$S_q(t)$	Entropie de Tsallis pour chaque classe individuelle dépendant du seuil t
$H_\alpha(P)$	Entropie de Rényi
$H_\alpha(t)$	Entropie de Rényi dépendant du seuil t
GI	Image originale
SI	Image segmentée

Introduction

La nouvelle ère de la communication s'annonce, l'évolution des sciences et des nouvelles technologies avec le progrès de l'électronique et de l'informatique, a fait de l'image un vecteur fondamental de l'information.

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

En plus, le progrès technologique des capteurs et de la capacité des mémoires de stockage, voit que de nombreuses images multispectrales avec une résolution spectrale et spatiale très élevées sont produites à chaque instant. Ce qui fait de l'image l'élément le plus en usage et le plus dominant dans une multitude de disciplines.

En effet, l'image de télédétection tant aérienne que satellite est le modèle visuel le plus riche de l'espace géographique. Elle est, pour l'instant, la source intarissable des informations les plus précises sur la couverture et l'utilisation du sol et sur les phénomènes qui se déroulent à la surface de la planète. Avec l'image satellite de très haute résolution spatiale, de nombreuses perspectives et applications s'ouvrent à la recherche dans les domaines de

l'environnement telles que l'hydrologie, l'agriculture, la détection des feux de forêts, le changement climatique, le développement urbain etc. La détection d'objets en imagerie demeure une opération importante dans l'analyse et le traitement des données. La segmentation de l'image satellites contribue de façon efficace à résoudre le problème de détection des différents types d'objet.

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

Toutefois, il n'existe pas de méthodes de segmentation universelles, le choix d'une technique est difficile puisqu'il est lié, notamment à la nature de l'image (éclairage, contours, texture,...), aux opérations en aval de la segmentation (compression, reconnaissance des formes, interprétation, mesure), aux primitives à extraire (droites, régions, textures,...) mais aussi aux contraintes d'exploitation (temps réel, mémoire,...).

Seulement, les résultats de la segmentation demeurent modestes [1] malgré la diversité des méthodes utilisées, et varient en fonction de la technique choisie. Ainsi, des erreurs de segmentation sont susceptibles d'intervenir comme : la sur-segmentation, qui génère des régions qui ne correspondent à aucun objet de la scène ou de la sous-segmentation, qui ne distingue pas l'ensemble des objets de la scène. Généralement, dans le domaine de la segmentation automatique, une seule méthode ne permet pas de segmenter convenablement la diversité des régions.

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

Pour apporter une solution à la segmentation, plusieurs méthodes ont été proposées ces dernières années. Nous citons celles qui exploitent l'information spectrale dans les images [2] et celles qui sont basées sur les caractéristiques spatiales de l'image [3].

Cependant, ces méthodes utilisent généralement des stratégies de segmentation qui ne prennent pas en compte les corrélations spectrales et spatiales qui peuvent exister entre les pixels de l'image. D'où la nécessité d'élaborer de nouvelles méthodes de segmentation qui tiennent compte, conjointement, de l'information spatiale et vectorielle contenue dans les images multispectrales.

Dans cette thèse, notre intérêt s'est focalisé sur la segmentation des images multispectrales, en particulier, les images satellite de très haute résolution spatiale –les images d'étude sont des images QuickBird MS–. Ainsi, nous présenterons trois approches de segmentation d'images multispectrales. La première, utilise une segmentation basée sur l'analyse hiérarchique des histogrammes 2D, la deuxième est basée sur l'approche quantique et la troisième est basée sur l'optimisation multiobjectif. Le but de ces trois méthodes est

d'aboutir à une meilleure segmentation d'images satellites multispectrales.

Cette thèse est effectuée en cinq chapitres structurés comme suit :

Dans le premier chapitre nous expliquerons, dans un premier temps, le processus de la télédétection spatiale, l'interaction existante entre le rayonnement électromagnétique et l'atmosphère ainsi que l'interaction entre le rayonnement et la matière nécessaire à la compréhension de la nature des signatures spectrales des principales surfaces naturelles.

Dans un deuxième temps, nous présenterons les caractéristiques des images satellites de très haute résolution spatiale : cas de l'imagerie QuickBird MS. Ensuite, nous exposerons le principe de composition colorée à partir d'images multispectrales, permettant de produire des images en couleur en tenant compte de la signature spectrale d'objets.

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

Le troisième chapitre est dédié à la segmentation basée sur l'analyse hiérarchique des histogrammes bidimensionnels, c'est une étude comparative de la segmentation d'images dans les espaces de couleur ***RGB*** et ***HSV***.

Le quatrième chapitre illustre deux approches de segmentation d'image de très haute résolution spatiale à savoir la méthode basée sur la fonction d'onde

appliquée aux images multispectrales et la méthode basée sur l'optimisation multiobjectif appliquée aux images panchromatique et aux images worldview. Les résultats obtenus ont été discutés permettant ainsi, de comparer ces techniques de segmentation et de quantifier leur apport.

En conclusion, nous rassemblerons les principaux résultats que nous aurons obtenu et mettrons les avantages et limitations des techniques que nous aurons élaboré en expliquant les principaux apports de celles-ci. Nous allons, aussi, donner les perspectives ouvertes par notre travail.

Chapitre 1

Les images multispectrales

1.1 Introduction

L'image de télédétection tant aérienne que satellite est le modèle visuel 3d le plus riche de l'espace géographique. C'est une source d'informations abondante et précise sur l'occupation du sol et sur les phénomènes que connaît la surface de la planète. Avec les images satellites, de nombreuses perspectives et applications s'ouvrent à la recherche, telles que l'hydrologie, l'agriculture, la détection des feux de forêts, le suivi des nuages ... etc. Les satellites emportent deux instruments : le radiomètre-imageur dans le visible et l'infrarouge en rotation amélioré ainsi que, l'instrument géostationnaire de détermination du bilan radiatif de la terre. Le radiomètre-imageur exploite plus de données que ses prédécesseurs, avec des résolutions spatiales, temporelles et spectrales plus poussées.

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

fin du chapitre, nous exposerons le principe des compositions colorées à partir d'images multispectrales, permettant de produire des images en couleur en tenant compte de la signature spectrale d'objets.

1.2 La télédétection spatiale




FIGURE 1.1 – Processus de la télédétection [6].

La télédétection spatiale permet d'observer le système terre, océans, atmosphère, en s'appuyant sur des méthodes d'acquisition de l'information à distance [4, 5]. Ces méthodes sont basées sur les propriétés du rayonnement électromagnétique. Les capteurs satellites permettent de mesurer l'énergie réfléchie et/ou émise par la surface de la terre et les océans ou par l'atmosphère.

Ils permettent aussi d'analyser et de suivre l'évolution de ces milieux au cours du temps. Le processus de la télédétection est donné par la figure 1.1.

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

1.2.1 La source d'énergie

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

1.2.2 Les interactions du rayonnement avec l'atmosphère

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

1.2.3 Les interactions du rayonnement avec la surface terrestre

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

1.2.4 L'enregistrement du signal par le capteur satellitaire

L'énergie réfléchi, émise ou rétro-diffusée par la surface de la terre est captée puis enregistrée et discrétisée au niveau du capteur satellite. On dis-

tingue deux types de capteurs en fonction de la source d'énergie :

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

1.2.5 La transmission et la réception des données

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

1.3 Le rayonnement électromagnétique

Le rayonnement électromagnétique correspond à l'ensemble des radiations émises par une source d'énergie qui peut être soit le soleil, ou bien encore le satellite lui-même. Les radiations sont émises sous forme d'ondes électromagnétiques ou de particules [4, 5].




FIGURE 1.2 – Spectre électromagnétique [6].

Le spectre électromagnétique, donné par la figure 1.2, représente la

répartition des ondes électromagnétiques en fonction de leur longueur d'onde.

En télédétection spatiale trois fenêtres spectrales sont principalement utilisées :

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

1.3.1 Le domaine du visible

La fenêtre du visible qui s'étend entre $0.4 \mu\text{m}$ et $0.7 \mu\text{m}$ est la seule fenêtre du spectre électromagnétique qui est perceptible par l'œil humain. La portion du spectre visible qui permet de visualiser les couleurs est donnée par la figure 1.3.




FIGURE 1.3 – Domaine du visible du spectre électromagnétique [6].

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

Couleur	Longueur d'onde (nm – 10.9 m)	Fréquence GHz
Violet	380 à 450 nm	725
Bleu	450 à 490 nm	640
Vert	490 à 570 nm	565
Jaune	570 à 585 nm	520
Orange	585 à 620 nm	500
Rouge	620 à 670 nm	465

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

1.3.2 L'infrarouge

Le domaine de l'infrarouge est relativement étendu puisqu'il couvre les longueurs d'onde de $0.7 \mu\text{m}$ à $100 \mu\text{m}$. Dans cette fourchette de longueurs d'onde, on distingue différents types d'infrarouges qui vont du proche infrarouge à l'infrarouge lointain, en passant par l'infrarouge moyen et le thermique.

a- Le proche infrarouge

Le proche infrarouge ($0.7 \mu\text{m}$ à $1.6 \mu\text{m}$) est la partie du spectre électromagnétique qui vient juste après le visible (couleur rouge). Les surfaces naturelles (forêt, végétation dense, etc...) se distinguent par une forte réflectance dans les longueurs d'onde du proche infrarouge, alors qu'elles réfléchissent peu le rayonnement dans le visible.

b- L'infrarouge moyen

L'infrarouge moyen ($1.6 \mu\text{m}$ à $4 \mu\text{m}$) permet, de façon générale, d'étudier les teneurs en eau des surfaces. Il est très utilisé en foresterie et en agriculture,

notamment pour cartographier les couverts végétaux.

c- L'infrarouge thermique

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

1.3.3 Les hyperfréquences

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

1.4 Le rayonnement et l'atmosphère

Le soleil et la surface terrestre émettent chacun un rayonnement électromagnétique comparable à celui d'un corps noir. Pour rappel, un corps noir est un corps qui absorbe tout le rayonnement qu'il reçoit et émet en retour un rayonnement thermique de manière à équilibrer le bilan radiatif. La luminance spectrale du corps noir [7, 8, 9, 10] ou la distribution spectrale de son émission dépend alors uniquement de sa température et obéit à la loi de Planck notée $B(T)$ et est donnée par :

$$B(T) = \frac{2hv^3}{C^2} \cdot \frac{1}{e^{((hv/K_B T))} - 1} \quad (1.1)$$

Où

v est la fréquence du rayonnement,

h est la constante de Planck,

K_B est la constante de Boltzmann,

C est la vitesse la lumière dans le vide, et

T est la température.

La distribution du rayonnement solaire correspond approximativement à celle d'un corps noir à une température de **5800K** à laquelle s'ajoute une série de raies d'absorption et d'émission dues aux éléments chimiques présents dans l'atmosphère solaire. L'émission solaire a essentiellement lieu de l'ultraviolet au proche infrarouge et est maximale dans le visible.

L'émission terrestre s'apparente à celle d'un corps noir à la température de 288K et elle est maximale dans l'infrarouge thermique. La figure 1.4 montre la distribution spectrale approximative du rayonnement solaire et terrestre. Les domaines de longueur d'onde des émissions sont presque totalement distincts, ce qui permet de différencier aisément chaque source.




FIGURE 1.4 – Spectre des corps noir à **5800K** et à **288K**, températures d'émission du soleil (bleu) et de la terre (rouge) [6].

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

1.4.1 Absorption et émission atmosphérique

Lorsque le rayonnement traverse la couche atmosphérique, il entre en collision avec les molécules et les particules présentes dans l'atmosphère. Il peut être dévié de sa trajectoire, c'est le phénomène de diffusion atmosphérique, ou bien être en totalité ou en partie absorbé. Dans ce dernier cas, il y a transfert d'énergie entre le rayonnement et les molécules avec lesquelles il entre en collision. L'absorption du rayonnement qui cède tout ou une partie de son énergie conduit par conséquent à une atténuation du signal dans la direction de propagation du rayonnement. La molécule change de configuration électronique. L'énergie absorbée modifie l'énergie interne de la molécule en la faisant passer d'un niveau d'énergie E_1 à un niveau d'énergie E_2 supérieur.

1.4.2 Diffusion atmosphérique

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

- la longueur d'onde du rayonnement
- la densité et la taille des particules et des molécules atmosphériques

— l'épaisseur de la couche atmosphérique à traverser.

On distingue ainsi trois types de diffusion :

a- La diffusion de Rayleigh

La diffusion de Rayleigh est due aux molécules gazeuses présentes dans l'atmosphère (O_2 , N_2 , CO_2 , *vapeur d'eau, etc.*) ou aux fines particules de poussière. Elle se produit lorsque la taille des molécules diffusantes est très inférieure à la longueur d'onde du rayonnement. La diffusion de Rayleigh est un phénomène sélectif qui se produit surtout pour les longueurs d'onde les plus courtes du spectre (violet, bleu). Elle affecte les hautes couches de l'atmosphère et c'est elle qui explique la couleur bleue du ciel pendant la journée. Les longueurs d'ondes les plus courtes (bleu) du rayonnement solaire sont plus diffusées que les longueurs d'onde plus grandes (rouge), aussi le ciel apparaît bleu à l'observateur.

b- La diffusion de Mie

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

c- La diffusion non-sélective

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

1.5 Le rayonnement et la matière

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

1.5.1 Les interactions entre le rayonnement et la matière

Lorsqu'un rayonnement électromagnétique atteint un objet, certaines longueurs d'onde sont absorbées tandis que d'autres sont réfléchies par l'objet. Une partie du rayonnement peut éventuellement être transmise à travers l'objet si celui-ci est plus ou moins transparent, avec un changement de direction de la propagation dû à la réfraction. Ces différentes interactions sont représentées

sur la figure 1.5. Les objets sont caractérisés par un coefficient d'absorption (α), un coefficient de réflexion (ρ), et un coefficient de transmission (τ), qui expriment respectivement la part d'énergie absorbée, réfléchie et transmise.




FIGURE 1.5 – Interaction du rayonnement électromagnétique avec la matière [6].

1.5.2 Les signatures spectrales des principales surfaces naturelles

En fonction de la nature et des caractéristiques intrinsèques des objets et des surfaces, le rayonnement incident interagira avec la cible selon l'une ou l'autre des propriétés citées précédemment. La signature spectrale d'un objet correspond à la quantité d'énergie réfléchie ou émise en fonction de la longueur d'onde. Ainsi, chaque surface possède une signature spectrale qui lui est propre et qui permettra son identification sur les images satellitaires [4, 5]. La figure 1.6 présente les signatures spectrales des surfaces naturelles dans le domaine du visible, du proche infrarouge, et de l'infrarouge moyen.

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

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




FIGURE 1.6 – Signature spectrale des surfaces naturelles dans le domaine du visible, du proche infra rouge et de l'infrarouge moyen [6].

1.6 Compositions colorées à partir d'images multispectrales

1.6.1 Images multispectrales

Une image est une représentation planaire d'une scène ou d'un objet situé en général dans un espace tridimensionnel. Son élaboration résulte de la volonté de proposer une entité observable par l'œil humain. Ceci explique d'une part son aspect planaire et d'autre part le fait que l'information élémentaire associée à chaque point de l'image soit transcrite en niveau de gris ou en couleur. Cette information élémentaire est, en général, une grandeur physique liée à la nature du capteur [11, 12].

L'image est donc une collection d'informations qui, dans un premier temps, se présentait sur un support photographique qui permettait le traitement en différé d'un phénomène fugace, une analyse fine des phénomènes enregistrés et bien sûr l'archivage et l'illustration. Le traitement d'images est né de l'idée et de la nécessité de remplacer l'observateur humain par la machine. L'image ou les signaux provenant des capteurs ont alors été numérisés pour pouvoir être traités par l'ordinateur. Dans un deuxième temps, l'image a été codée et mémorisée sur différents supports (magnétique, magnéto-optique, etc.). La vision intervenant dans un grand nombre d'activités humaines, le champ des applications du traitement d'images est très vaste [11, 12].

Les données digitales utilisées tout au long de la recherche sont d'une scène QuickBird-2 acquise le 15 Juin 2006. Géographiquement, cette zone représente une partie du paysage urbain, océan atlantique et du paysage d'arrière pays (terrain agricole, forêt,...) spécifique de la préfecture de Skhirate-Temara, elle couvre environ **90km²**. 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 $\lambda_2 = 33^{\circ}56'34.57''N$.

QuickBird-2 fournit des données multispectrales de 16 bits dans les bandes rouge, verte, bleue et proche infrarouge à **2,41m X 2,41m** de résolution spatiale (Figure 1.7) et une autre bande panchromatique de 11 bits à une résolution de **0,6m X 0,6m** (Figure 1.8). 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 Pan-sharp. Le tableau 1.2 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 1.2 – Caractéristiques des bandes multispectrales de l'image QuickBird MS.

1.6.2 Compositions colorées à partir d'images multispectrales

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



FIGURE 1.7 – © Digital Globe : Zone d'étude –QuickBird **RGB** Image couleur composite réalisée à partir des bandes 321, acquise le 15 juin 2006 à 12h –.

Ainsi, avec les quatre bandes spectrales, un grand nombre de compositions colorées peuvent être réalisées. Mais en règle générale, on ne combine que les bandes spectrales qui présentent des propriétés physiques différentes. La fausse image en couleur est composée de bandes suivantes : proche infrarouge, rouge et verte. Dans la fausse image en couleur de la figure 1.9, la couleur rouge représente la végétation, la couleur noire indique l'eau et la couleur blanche représente les routes.




FIGURE 1.8 – © Digital Globe : Zone d'étude : Image Panchromatique acquise le 15 juin 2006 à 12h.

L'image de la figure 1.9, présente une composition, en fausses couleurs, réalisée à partir des bandes spectrales Proche infrarouge, Rouge, Bleu du satellite QuickBird. Cette image a été construite en assignant les canaux Proche Infra-Rouge, Rouge, Bleu aux composantes rouge, verte, et bleu, respectivement. Les couleurs résultantes sont la fonction des valeurs numériques des pixels dans chacune des trois bandes spectrales.




FIGURE 1.9 – Image QuickBird composite en fausses couleurs réalisée à partir des bandes IR G B 421.

1.7 Discussion

Dans ce chapitre, nous avons exposé le processus de la télédétection spatiale, où nous avons mis en relief l'interaction entre le rayonnement et l'atmosphère. En effet, ce sont les constituants de l'atmosphère qui confèrent, au système Soleil-Atmosphère-Terre, un caractère aléatoire, car en absence d'atmosphère, ce système serait complètement déterministe.

Ensuite, nous avons montré l'interaction entre le rayonnement et la matière ainsi que l'effet de celle-ci sur la signature spectrale dans des surfaces de

scènes naturelles.

Dans un deuxième temps, nous avons donné les principales caractéristiques de l'imagerie QuickBird, ce qui a permis de mettre en évidence les propriétés spatiales, temporelles et spectrales du radiomètre imageur. Nous avons, aussi, montré que la composition colorée, à partir des différentes bandes spectrales, permet de détecter les différentes classes constituant l'image à traiter. Par conséquent, l'image composite colorée et l'image au niveau de gris peuvent également être utilisées pour une interprétation de l'image satellite.

En conclusion, la segmentation d'images satellites est fondamentale pour une meilleure analyse et interprétation de la classification de la couverture, ainsi que de l'utilisation des sols urbains.

Chapitre 2

Segmentation et Classification des Images Multispectrales

2.1 Introduction

L'analyse des images a pour but l'extraction de l'information caractéristique contenue dans celles-ci. Le résultat d'une telle analyse s'appelle très souvent la description structurelle. Elle peut prendre la forme d'une image ou de toute structure de données permettant une description des entités qu'elle renferme. Par opposition avec la phase d'interprétation, l'analyse tente, dans la mesure du possible, de ne pas prendre en compte le contexte (i.e. l'application).

Essentiellement, l'analyse de l'image fait appel à la segmentation où l'on va tenter d'associer à chaque pixel de l'image un label en s'appuyant sur l'information portée (niveaux de gris ou couleur), sa distribution spatiale sur le support image, et des modèles simples (le plus souvent des modèles géométriques).

Dans ce chapitre, d'une part, nous allons définir la couverture du sol, son utilisation aussi que son complémentarité, d'autre part, nous allons présenter quelques techniques de segmentation et de classification d'images.

2.2 Couverture et utilisation du sol

Même si les termes couverture du sol et utilisation du sol se ressemblent, ils sont définis de façons très différentes. La couverture du sol fait référence au sol nu, à la végétation, aux infrastructures, à l'eau etc... [13, 14, 15]

L'identification, le tracé et la cartographie de la couverture du sol sont importants pour les études de surveillance planétaire, de gestion des ressources et de planification d'activités. L'identification de la couverture du sol établit la ligne de base à partir de laquelle des activités de suivi (et de détection) des changements peuvent être effectuées, et fournissent des informations préliminaires pour les cartes thématiques.

L'utilisation du sol fait référence à l'usage qu'on fait du sol, par exemple les loisirs, l'habitat, la faune ou l'agriculture. L'application de l'utilisation du sol comprend la cartographie de base ainsi que la surveillance qui en découle, vu que des informations adéquates sont nécessaires pour connaître la superficie du sol compatible à chaque type d'utilisation, ainsi que pour identifier les changements d'utilisation au fil des années. Ces connaissances permettront le développement de stratégies visant à équilibrer les utilisations conflictuelles et les pressions de l'urbanisation. En effet, la disparition et les perturbations des terres arables, l'urbanisation et la détérioration des forêts stimulent, incessamment, le développement d'études sur de l'utilisation du sol.

Par conséquent faire la distinction entre la couverture du sol et l'utilisation du sol, ainsi que les informations que nous pouvons en retirer s'avèrent fondamentales. Les propriétés mesurées par la télédétection se rapportent à la couverture du sol, à partir de laquelle l'utilisation du sol peut être déduite à l'aide de données auxiliaires ou de connaissances préalables [16, 17, 18].

L'étude de la couverture et de l'utilisation du sol est multidisciplinaire. En plus de faciliter la gestion durable des terres, elles peuvent être utilisées pour la planification, la surveillance et l'évaluation du développement, de l'activité industrielle ou des réclamations. La détection de changements des couvertures du sol à long terme peut indiquer une réaction aux modifications des conditions climatiques locales ou régionales qui sont, même, la base de la surveillance à l'échelle du globe.

L'intérêt porté aux changements dans la couverture du sol devient de plus en plus le souci de tout le monde, surtout celui des scientifiques actifs dans le domaine de la protection de la terre et de la gestion des ressources naturelles, qui s'engagent davantage dans diverses études d'analyses et de développement des systèmes d'aide à la décision, ainsi que dans des démarches de sensibilisation, au profit du grand public soucieux du problème des sols liés à l'environnement tels que; la protection et la gestion des ressources naturelles, le développement durable, ...etc [18].

L'importance de la couverture du sol et de l'utilisation du sol repose sur une meilleure analyse et interprétation d'images satellites, la segmentation et la classification d'images satellites demeurent, par conséquent, d'un grand intérêt.

2.3 Les principes de la segmentation

La segmentation consiste à extraire des primitives, soit de type contour, soit de type régions. Ces primitives seront exploitées lors de la reconnaissance de formes, de recalage, de la mise en correspondance, de la compression, ...

d'après Trémeau [19].

La segmentation d'images consiste à transformer une image en image binaire ou bien une image en régions. Concernent la segmentation en région, les pixels de chaque région sont étiquetés par la même étiquette. Une grande partie de notre travail est consacrée à la segmentation des images couleurs. En effet, il nous semble essentiel de comprendre comment se forme la couleur et les principaux facteurs qui l'influencent avant d'aborder le problème de la segmentation. La couleur d'un objet, telle que nous la percevons, est une notion très compliquée qui obéit à des lois physiques, physiologiques et psychologiques particulières [20]. C'est pour cette raison que le chapitre I est consacré à : la mesure, la formation de la couleur qui est liée très fortement à la lumière et les différents systèmes de représentation de la couleur.

La segmentation d'images fait référence aux notions de différence et de similarité comme les perçoit le système visuel humain. C'est ces deux notions qui sont à l'origine de l'approche contour et de l'approche région [11].

La segmentation d'images [21], ainsi définie, est un domaine vaste où l'on retrouve de très nombreuses approches à savoir :

- Le seuillage
- La détection de frontières
- La modélisation
- La Transformée de Hough
- La recherche de régions
- L'approche de la classification

Toutes ces approches visent à l'extraction d'indices visuels. Après avoir passé de nombreuses années à rechercher d'une méthode optimale, les chercheurs ont conclu que la segmentation idéale n'existait pas. On peut même dire que la façon par laquelle le problème de la segmentation est posé est défailante. Vu que pour une seule image, plusieurs segmentations sont possibles.

Une bonne méthode de segmentation est celle qui permettra une bonne interprétation. Elle devrait simplifier l'image sans pour autant en avoir trop réduit le contenu et, entre autres, éviter les choix irréversibles. L'avenir de la segmentation se place dans le pilotage en aval par l'application.

Globalement, la segmentation peut être définie comme une partition d'une image I en une région ou plusieurs régions $R_1, \dots, R_n$ telles que :

$$I = \bigcup_{i=1}^n R_i \text{ et } R_i \cap R_j = \emptyset \text{ pour tout } i \neq j \quad (2.1)$$

2.4 Les indices visuels

Les indices visuels sont des objets extraits de l'image, qui renferment, de manière concise, une information importante pour son analyse. Généralement, ces indices sont ; soit des contours ou des régions de l'image, ces deux éléments se complètent. En effet, au sens d'un certain critère, on définit qualitativement les régions comme les zones homogènes de l'image tandis que les contours sont les espaces de transition entre ces zones.

Les propriétés requises par les indices visuels dépendent de l'application et sont en général un sous-ensemble de la liste ci-dessous :

- **Compacts** : *la représentation de l'image doit être la plus concise pour réduire la complexité des algorithmes ultérieurs.*
- **Intrinsèques** : *les indices visuels doivent, en particulier, correspondre à la projection dans l'image d'objets physiques et doivent être invariants par changement de point de vue.*
- **Robustes** : *la représentation doit être peu sensible aux petites variations d'intensité dans l'image provoquée par des bruits divers tels que ceux liés à l'acquisition, la digitalisation, etc...*
- **Discriminants** : *les indices visuels doivent posséder des propriétés permettant leur discrimination et ce pour une mise en correspondance entre deux descriptions (pour la reconstruction tridimensionnelle ou pour l'appariement avec un modèle).*
- **Précis** : *le calcul de la position des indices visuels doit se faire avec précision vu que la qualité de la localisation des objets physiques en dépend.*
- **Denses** : *la densité des indices visuels doit être suffisante pour représenter tous les objets intéressants de la scène.*

Dans cette thèse nous allons mettre l'accent sur la segmentation qui s'intéresse au seuillage des histogrammes bidimensionnels.

2.5 Le seuillage

2.5.1 Principes du seuillage

Le seuillage a pour objectif de segmenter une image en plusieurs classes, seul l'histogramme est utilisé [22]. On suppose, donc, que l'information, à elle seule, associée à l'image permet la segmentation, i.e. que chaque classe est caractérisée par sa distribution de niveaux de gris et qui ; à chaque pic de l'histogramme, est associée une classe.

Il existe de très nombreuses méthodes de seuillage d'un histogramme, dont la plupart d'entre elles s'appliquent correctement si l'histogramme contient réellement des pics séparés. De plus, elles ont été très souvent développées pour traiter le cas particulier de la segmentation en deux classes (i.e. passage à une image binaire) aussi, leur généralité face aux cas multiclassés n'est que très rarement garantie.

2.5.2 La détection de vallées

La détection de vallées est la technique la plus intuitive [23]. On suppose que chaque classe correspond à une gamme distincte de niveaux de gris. L'histogramme est alors m -modal : On peut alors dégager $(m - 1)$ seuils pour séparer les m classes et minimiser, au mieux, l'erreur de segmentation. Il est logique de choisir ces seuils sur la position des minima de l'histogramme H .

La méthode des modes, que nous présentons ici, consiste à identifier les m maxima principaux de l'histogramme H et à détecter les $m - 1$ minima les séparant. En termes mathématiques, les seuils s_i sont obtenus par :

$$H(s_i) = \text{Min}.H(k)_{k=]m_i, m_{i+1}, \dots, m_{i+1}[} \quad (2.2)$$

où m_i et m_{i+1} sont les valeurs moyennes (ou les modes) de l'intensité lumineuse dans les classes C_i et C_{i+1} .

Il existe des techniques robustes développées pour faciliter la détection des vallées. Ces méthodes, bien que simples, sont très peu appliquées car les histogrammes traités sont le plus souvent bruités et uni-modaux (c'est à dire composés d'un seul pic principal) ou bi-modaux si on considère des images représentant des objets foncés (respectivement clairs) sur des images claires (respectivement foncées). Un exemple d'image bi-modale est illustré en figure 2.1.




FIGURE 2.1 – Exemple d'image et d'histogramme bi-modale [24].

Un exemple de découpage en 4 classes est illustré quant à lui sur la figure 2.2.




FIGURE 2.2 – Exemple de seuillage en 4 classes par histogramme [24].

Il est souvent important de mentionner qu'il faut éviter de prendre deux maxima locaux appartenant à un même "pic" (maximum global) sous peine de sur-discriminer les classes (voir un exemple sur la figure 2.3). On peut alors fixer une distance minimale entre les maxima ou filtrer l'histogramme afin de le lisser.




FIGURE 2.3 – Histogramme bi-modal dont les deux pics principaux présentent des maxima locaux non pertinents pour la segmentation [24].

Si cette segmentation, simple à mettre en œuvre, est assez robuste, elle ne fonctionne, en revanche, que sur un nombre limité de cas : les histogrammes

bi-modaux.

De plus, il est facile de remarquer, dès à présent, que la segmentation, en elle-même, ne permet pas de définir des objets, mais uniquement des ensembles de pixels, dont rien n'assure qu'ils sont connexes (c'est-à-dire connectés entre eux).

2.5.3 La minimisation de variance

La répartition des pixels en N classes est un problème classique de classification. Le choix des seuils s_i permet de détecter m classes auxquels on peut associer taille (t_i), moyenne (m_i) et variance v_i par :

$$t_i = \sum_{D_j} H(j), \quad m_i = \sum_{D_j} \frac{jH(j)}{t_i}, \quad v_i = \sum_{D_j} \frac{(j - m_i)^2 H(j)}{t_i} \quad (2.3)$$

Où H est l'histogramme normalisé (son intégrale est ramenée à l'unité) et $D_j = [s_{i-1}, s_i[$ est la gamme de niveaux de gris correspondant à la classe C_i (par hypothèse, $s_0 = 0$).

A partir de ces indicateurs statistiques, on peut construire la variance intra-classe totale W par :

$$W = \sum_i t_i \cdot v_i \quad (2.4)$$

Le meilleur seuillage dans cette approche correspond à une minimisation de la variance intra-classe (méthode de Fisher). Cette technique est difficilement applicable lorsque le nombre de classes est élevé. En effet, il faut tester exhaustivement tous les $(N - 1)$ -uplés $(s_1, \dots, s_{N-1})$ possibles. De plus, il faut que chaque classe ait une taille significative en nombre de niveaux

de gris pour que les indicateurs statistiques aient un sens. Dans le cas de la binarisation ($N = 2$), cette méthode est performante.

OTSU [25] a proposé de réaliser une maximisation de la variance inter-classe B qui s'exprime dans le cas de la binarisation par :

$$B = t_0.t_1(m_0 - m_1)^2 \quad (2.5)$$

ce qui est rigoureusement équivalent puisque l'on a la relation : $W + B = \textit{constante}$

Cependant, la méthode d'OTSU est plus intéressante d'un point de vue calculatoire car elle ne nécessite pas de calcul de variances.

2.5.4 Seuillage entropique

Le seuillage entropique est une technique dérivée de la théorie de l'information. La motivation de l'application du seuillage entropique pour résoudre le problème de la sélection des seuils réside dans le succès rencontré par cette méthode dans de nombreux cas d'applications, telles que la restauration d'images ou la reconnaissance de cible [26, 27].

Les seuils sont déterminés de manière à maximiser l'entropie E_{TP} résultant du découpage de l'histogramme H en plusieurs classes. En effet, l'entropie mesure la quantité d'information portée par un groupe. Pour un nombre de seuils fixe, on cherche à ce que les classes résultantes portent le maximum d'information.

L'entropie totale est calculée de la manière suivante :

$$E_{TP} = \sum_i E_{TP}(C_i) \quad (2.6)$$

où C_i désigne la classe $n^o i$ et :

$$E_{TP}(C_i) = \sum_{D_i} p_j \log_2(p_j) \quad (2.7)$$

où D_i est l'ensemble des niveaux de gris j associés à la classe C_i et p_j la probabilité a posteriori du niveau de gris j , estimée par

$$p_j = \frac{H(j)}{N.M} \quad (2.8)$$

(N et M représentant les dimensions de l'image)

La notion d'entropie n'est pas liée à une caractéristique visuelle. C'est pourquoi l'image résultat paraît le plus souvent de qualité moins bonne (du point de vue de l'œil humain) qu'une image obtenue par une des techniques présentées dans ce chapitre.

2.5.5 Méthode du pourcentage

Dans certains cas, une connaissance a priori de la scène, si celle-ci est simple, permet de choisir les seuils. En particulier, si l'image est constituée de deux entités, la connaissance de la fraction surfacique F de l'une des deux

phases peut être reliée au seuil $\mathbf{s}$ par :

$$|\mathbf{d}(\mathbf{s}) - \mathbf{F}| = \text{Min}|\mathbf{d}(\mathbf{k}) - \mathbf{F}| \quad (2.9)$$

où $\mathbf{d}(\mathbf{k})$ représente l'intégrale normalisée de l'histogramme entre les bornes $\mathbf{1}$ et $\mathbf{k}$.

Cette technique peut être appliquée au seuillage de pages de caractères, si la densité dans une page est connue. Cependant, elle ne s'applique que dans des applications particulières et la généralisation au cas de $\mathbf{m}$ classes est difficilement envisageable. Par contre, si la connaissance de $\mathbf{F}$ est rarement suffisante, elle peut faciliter la modélisation de l'histogramme.

2.5.6 Maximisation du contraste

Bien que déterminant des seuils, cette technique ne fait pas appel à l'histogramme mais utilise directement la répartition spatiale des niveaux de gris $\mathbf{g}(\mathbf{i})$ dans l'image. Ici, elle est présentée dans le cas de la binarisation. L'objectif est de trouver le seuil qui va introduire le maximum de contraste dans l'image résultat.

Soit $\mathbf{k}$ un seuil donné. On construit l'ensemble $\mathbf{K}$ par :

$$\mathbf{K}(\mathbf{k}) = \{(\mathbf{a}, \mathbf{b}) / \mathbf{g}(\mathbf{a}) \leq \mathbf{k} \leq \mathbf{g}(\mathbf{b})\} \quad (2.10)$$

où $\mathbf{a}$ et $\mathbf{b}$ sont deux pixels voisins dans l'image (pour un ordre de voisinage à

fixer). A cet ensemble, on associe la mesure de contraste suivante :

$$C(\mathbf{k}) = \sum_{\mathbf{K}(\mathbf{k})} \text{Min}(|g(\mathbf{a}) - \mathbf{k}|, |g(\mathbf{b}) - \mathbf{k}|) \quad (2.11)$$

La valeur retenue pour le seuil sera celle qui maximisera le ratio $C(\mathbf{k})/\text{Card}[\mathbf{K}(\mathbf{k})]$. Cette méthode, en apparence complexe, est très intéressante car elle introduit la notion de contexte dans l'étude des couples de pixels voisins. Par conséquence, l'histogramme des niveaux de gris n'est plus la seule source d'information. Cette idée sert de base aux méthodes contextuelles.

2.5.7 Bilan sur le seuillage

Les méthodes de segmentation basées sur le choix d'un ou plusieurs seuils sont, aujourd'hui, utilisées dans des applications très particulières. On les retrouvera en contrôle qualité où la maîtrise du milieu ambiant et la simplicité des scènes permettent d'avoir de très bonnes conditions d'éclairage. On peut ainsi assurer au mieux l'hypothèse de séparabilité des phases nécessaires au bon fonctionnement de ce type de méthodes.

C'est dans ce type d'application que l'on exploite le mieux les deux grands avantages du seuillage : la simplicité et la rapidité. Ces deux caractéristiques sont liées. En effet, la simplicité des algorithmes permet souvent la réalisation d'opérateurs câblés permettant la rapidité nécessaire dans le contexte du temps réel qui est le contexte habituel des applications industrielles.

Bien que nécessitant des paramètres, les techniques de seuillage peuvent fonctionner en mode autonome. Il est possible d'affiner un seuil par comparaison entre l'image initiale et l'image seuillée ou bien en rajoutant des contraintes sur la qualité (à définir) de l'image seuillée. Cette mesure peut

être interprétée en termes d'évaluation de l'erreur de classification.

L'histogramme étant une fonction trop globale, on peut envisager un seuillage qui ne soit pas fixe. Pour cela, l'image est décomposée en sous-images. Sur chacune d'elles, est appliquée une technique classique de seuillage. Cependant, ce processus risque d'introduire des discontinuités. De plus, si les sous-images sont trop petites, les histogrammes ne contiendront pas assez de valeurs pour être statistiquement exploitables. Cette technique est à réserver à des configurations particulières (dérive lumineuse par exemple).

Cependant, ces méthodes ne sont pas suffisantes pour la plupart des applications, où la complexité de l'information contenue dans l'image ne peut être résumée par l'histogramme des niveaux de gris, sans trop de pertes d'informations.

2.6 La recherche de régions

2.6.1 Le modèle de région

La segmentation d'une image vis-à-vis d'un critère d'homogénéité $\mathbf{H}$ (par exemple "tous les pixels sont du même niveau de gris" ou "la variation de niveau de gris n'excède pas n niveaux") peut s'exprimer de la manière suivante : La segmentation d'une image $\mathbf{I}$ en regard du critère $\mathbf{H}$ est une partition de l'image $\mathbf{I}$ en n régions homogènes $\mathbf{X}_1, \dots, \mathbf{X}_n$ telles que :

$$\bigcup_{i=1}^n \mathbf{X}_i = \mathbf{I} \quad (2.12)$$

Pour tout i , $\mathbf{X}_i$ est connexe

Pour tout i , $H[X_i]$ est vrai

Pour tout couple (X_i, X_j) de régions voisines, $H[X_i, X_j]$ est faux

Cette définition conduit à deux remarques très importantes. Tout d'abord, une segmentation dépend du critère utilisé; le choix du critère est donc primordial. Ensuite, la décomposition obtenue n'est pas unique; pour un critère donné, il existe plusieurs solutions.

2.6.2 La croissance de région

Les techniques de seuillage n'assurent pas la connexité des zones détectées. C'est – entre autres – ce qui permettent de résoudre les techniques dites de croissance de région.

Le principe d'un algorithme de type croissance de région est le suivant :

- On se fixe un point de départ dans l'image. Ce point est appelé germe de la région cherchée.
- On se fixe un critère d'homogénéité de la région cherchée (par exemple une intensité comprise entre deux valeurs ou des critères de texture).
- Par une procédure récursive (i.e. de proche en proche), on inclut dans la région tous les points connexes qui vérifient le critère.
 - On fait, ainsi, croître la région tant que le critère est respecté.
 - On obtient une région connexe.

2.7 L'approche de la classification

2.7.1 Introduction

La nature vectorielle des images en couleur ou multispectrales implique la mise en œuvre de stratégies de segmentation spécifiques. Il n'existe pas de méthode de segmentation universelle et le choix d'une technique dépend :

- des caractéristiques de l'image (ombre et reflets, présence de bruit ou de zones texturées, contours flous ou masqués),
- du type d'analyse à effectuer (reconnaissance de formes, mesures quantitatives, calcul statistique, diagnostique, contrôle qualité),
- des primitives à extraire (contours, régions, formes, textures),
- des contraintes d'exploitation (complexité algorithmique, temps de calcul, espace mémoire).

Parmi les différentes stratégies de segmentation couleur, celles fondées sur la classification de données multidimensionnelles, permettant une approche globale particulièrement bien adaptée à l'identification de marqueurs colorés dans des images bruitées. Un algorithme original de classification a été développé pour segmenter des séries d'images couleur présentant une forte variabilité.

2.7.2 Les méthodes de classification

La classification est une opération préalable à la segmentation ; elle consiste à regrouper en classe les pixels de l'image ayant des caractéristiques colorimétriques similaires ; une image couleur ou imagerie multispectrales sera considérée comme un ensemble non ordonné de vecteurs et chaque pixel sera affecté à une classe unique indépendamment de ses voisins.

La classification s'effectue dans l'espace colorimétrique de l'image (Figure 2.4) et repose sur le principe suivant :

- Il est possible de regrouper dans une même classe tous les pixels appartenant à une même région de l'image.
- Les pixels appartenant à une classe, peuvent former plusieurs régions non adjacentes de l'image.




FIGURE 2.4 – Classification dans l'espace RGB .

Les modèles de classification opèrent en deux temps [28] : (i) la phase d'apprentissage consiste à construire les classes de pixels en déterminant leurs caractéristiques ; (ii) dans la phase de décision, chaque pixel est affecté à une

classe en fonction de ses coordonnées colorimétriques. Selon la nature de la phase d'apprentissage, on distinguera deux familles de méthodes :

- La classification avec apprentissage non supervisé consiste à découper l'espace colorimétrique en zones homogènes selon un critère exprimé dans l'espace des composantes [29]. Cette approche permet une classification « en aveugle » et réalise une segmentation sans connaissance a priori de l'image. Selon qu'il est nécessaire ou / non de fixer au préalable le nombre de classes dans l'image, on distinguera classiquement (i) les méthodes de regroupement héritées de la classification de données multidimensionnelles et (ii) celles fondées sur l'analyse d'histogrammes qui déterminent automatiquement le nombre.
- La classification avec apprentissage supervisé nécessite de fournir pour chaque classe un ensemble de pixels représentatifs de la segmentation que l'on souhaite obtenir. Le nombre de classes doit donc être connu au préalable et repose, de même sur le choix de l'ensemble d'apprentissage, sur une connaissance a priori des images à segmenter.

2.8 Classification non supervisée par analyse hiérarchique d'histogramme 2D

La reconnaissance automatique de marqueurs colorés dans des séries d'images présentant une forte variabilité requiert l'emploi de méthodes non supervisées et robustes [30]. Les méthodes de classification par analyse d'histogrammes ont l'avantage de réaliser une segmentation sans connaissance a priori des images. La sélection des pics d'histogrammes repose sur des valeurs

de seuils qui ne dépendent pas de la nature des images mais du nombre de classes que l'on souhaite obtenir : quelque soit la méthode utilisée, plus l'effectif requis pour la reconnaissance des pics sera faible plus le nombre de classes engendrées sera important. L'adéquation entre classes et régions suppose que des régions homogènes de l'image correspondent à des pics identifiables dans l'histogramme. La segmentation sera donc directement influencée par le choix de l'espace colorimétrique. Les méthodes de classification par analyse d'histogrammes ne prennent pas en compte l'information spatiale ; cette information est par nature sensible au bruit et délicate à exploiter quand la variabilité des images est importante. Il en résulte un avantage en termes de robustesse pour la connaissance de couleurs dans des séries d'images bruitées. Il n'existe en pratique que peu de méthodes performantes d'analyse d'histogrammes multidimensionnels. Nous proposons une nouvelle méthode d'analyse d'histogrammes 2D ne nécessitant aucune quantification colorimétrique.

2.8.1 Principe

L'histogramme 2D d'une image $\mathbf{I}$ peut être représenté par une image $\mathbf{J}$ dont les dimensions spatiales sont celles des deux axes choisis dans l'espace colorimétrique associé à $\mathbf{I}$. Si les composantes colorimétriques de $\mathbf{I}$ sont codées chacune sur Q bits, $\mathbf{J}$ sera de dimension $2Q \times 2Q$. chaque pixel p_j de $\mathbf{J}$ a pour valeur l'effectif de l'histogramme au point colorimétrique défini par les coordonnées spatiales de p_j . Une image 8 bits sera constituée en normalisant les effectifs non nuls entre 1 et 255, la valeur 0 traduisant les effectifs nuls. Grâce à cette représentation, l'analyse de l'histogramme pourra être effectuée en utilisant les outils d'analyse d'images en niveaux de gris, l'image étant alors interprétée comme un relief défini par la valeur des pixels.

La phase d'apprentissage est réalisée par décomposition hiérarchique de l'image d'histogramme en construisant une arborescence des pics représentatifs des classes : à chaque niveau de gris de l'image $\mathbf{J}$, les pics sont identifiés par un étiquetage en composantes connexe des valeurs de l'image supérieures ou égales au niveau de gris considéré [31]. Chaque pic sera ensuite décomposé de manière récursive en pics plus fins, des niveaux de gris les plus faibles jusqu'aux niveaux les plus élevés. Un pic ne pourra être décomposé que si au moins deux des sous-pics formés possèdent un effectif supérieur à un seuil $\mathbf{S}$. ce seuil est exprimé en pourcentage du nombre de pixels correspondants dans l'image $\mathbf{I}$. Ainsi, le nombre de classes dépendra de la précision avec laquelle on analyse les couleurs de l'image, en considérant ou non comme significatives des couleurs faiblement représentées et traduites sur l'histogramme par des pics de moindre importance. La figure 2.5 présente sur un exemple, le principe de la décomposition hiérarchique. Pour la clarté du schéma, l'histogramme dessiné est à une seule dimension.




FIGURE 2.5 – Exemple de décomposition hiérarchique [31].

En rouge, figurent les nœuds effectivement construits, les feuilles entourées d'un cercle correspondent aux pics reconnus. En noir, figurent les branches explorées et les nœuds ou feuilles non retenus à cause d'un effectif inférieur au seuil S . Dans la phase de décision, les pixels non attribués aux pics sont affectés aux classes en choisissant pour chaque pixel la classe qui minimise la distance colorimétrique avec le centre de gravité du pic correspondant. En cas d'égalité, la classe de plus faible indice sera choisie. Les pixels sont classés en respectant la décomposition hiérarchique de l'histogramme : une valeur colorimétrique ne pourra être affectée qu'à une classe fille de la classe à laquelle elle appartient à un niveau hiérarchique moins élevé.

2.8.2 Expérimentations

Sur la base de l'analyse hiérarchique des histogrammes 2D qui est développé au chapitre 3, nous avons développé deux algorithmes de segmentation d'images de très haute résolution spatiale :

- le premier algorithme est basé sur la fonction d'onde et la résolution de l'équation de Schrödinger appliqué à la segmentation de la couverture et de l'utilisation du sol de l'imagerie multispectrales,
- le second algorithme est basé sur l'optimisation multiobjectif appliqué à la segmentation d'image en niveaux de gris : Image panchromatique et Image Worldview.

2.9 Conclusion

Les résultats d'expérimentation de ces deux algorithmes dépendent essentiellement des choix de l'algorithme à adopter, des critères d'évaluation pour lesquels opter, ainsi que la variété d'images sélectionnées (images synthétiques, images multispectrales et images panchromatiques).

En pratique, les résultats obtenus par les techniques citées auparavant montrent que l'utilisation conjointe de ces deux aspects, est d'une importance majeure pour la segmentation d'images multispectrales. Malgré la complexité des détails composant ces images, les différents résultats de segmentation, montrent que les images traitées ont été correctement segmentées.

Vue l'importance de la classification de la couverture et de l'utilisation du sol que nous avons défini auparavant, la segmentation des images satellites par l'analyse hiérarchique des histogrammes 2D est d'une importance considérable que nous allons voir au troisième chapitre.

Chapitre 3

Segmentation d'images à l'aide d'analyse hiérarchique des histogrammes 2D

3.1 Introduction

La nouvelle génération des capteurs d'imagerie à très haute résolution spatiale comme Ikonos et QuickBird crée des attentes fortes pour la télédétection des zones urbaines telles que la couverture et l'utilisation des sols urbains [32]. La couverture du sol se réfère à l'individualité physique de la surface de la Terre, qui est capturée par la végétation, le sol, les plans d'eau et d'autres caractéristiques physiques du terrain. L'utilisation du sol se réfère à la façon dont la terre a été utilisée par les humains et leur habitat, habituellement pour des activités économiques [33]. L'identification de la couverture du sol et l'utilisation du sol en milieu urbain peut être atteinte par la classification des pixels des images multispectrales en utilisant les méthodes de segmentation.

La segmentation s'exprime par les techniques et les procédures qui sont utilisées pour diviser l'image en différentes régions, en fonction de leurs caractéristiques, de sorte à ce que ne se chevauchent pas. Les valeurs de pixels de la même région ont des attributs similaires, tandis que leurs valeurs entre différentes régions ont des attributs différents. Diverses méthodes de segmentation peuvent être trouvées dans la littérature, qui peuvent être globalement classées en plusieurs catégories selon les caractéristiques dominantes qu'elles

emploient, telles que les méthodes basées sur le contour [34, 35, 36, 37], les méthodes de croissance des régions [38], Les méthodes de réseaux neuronaux, les méthodes basées sur la physique [39, 40, 41, 42] et les méthodes de seuillage d'histogramme [43].

Les nombreux problèmes de segmentation pratiques ont besoin de plus d'informations que celles contenues dans une seule bande d'images, dans ces cas, l'utilisation de plusieurs composantes d'images couleurs ou d'images multispectrales devient nécessaire [44]. Il existe deux problèmes critiques pour la segmentation de l'image couleur : (1) la façon dont la méthode de segmentation doit être utilisée et (2) la façon dont l'espace colorimétrique doit être adopté [34, 35, 36, 37]. Il a été démontré que, face à des problèmes de classification non supervisée, l'histogramme de seuillage est une méthode appropriée pour réaliser la segmentation d'image à plusieurs classes avec une complexité de calcul faible [36, 37, 39, 41]. En l'occurrence, les algorithmes de classification basés sur l'analyse d'histogramme-2D, obtenus par projection de l'histogramme multidimensionnel sur deux plans couleur, ont été développés et utilisés avec succès [31, 45].

A noter que l'espace de couleur **HSV** est fondamentalement différent de celui de **RGB**. Ce dernier est largement connu car il sépare l'intensité de l'information de couleur (chromaticité). Autrement dit, les trois composantes **H** (Teinte), **S** (Saturation) et **V** (Valeur) correspondent aux attributs de couleur étroitement associés à la façon dont l'œil humain perçoit les couleurs [36, 37]. De nombreux travaux liés à l'image couleur ont été rapportés en utilisant cet espace colorimétrique [42, 46].

Cette étude est scindée en deux parties. La première consiste à une analyse

théorique de la nouvelle méthode de segmentation couleur numérique, basée sur l'analyse hiérarchique des histogrammes 2D. L'algorithme de segmentation est accompli par la reclassification des pixels qui ne sont pas classés dans les classes déterminées selon la distance de Mahalanobis. La seconde est liée à une évaluation pratique de l'algorithme appliqué à la classification de la couverture et de l'utilisation des sols urbains de l'image QuickBird sélectionnée faisant partie de la préfecture de Skhirate-Temara, (Rabat-Salé-Kénitra) Maroc.

3.2 Méthodes et matériels

3.2.1 Traitement Numérique des images

La classification des pixels **RGB** pourrait être réalisée en utilisant une analyse hiérarchique de l'histogramme bidimensionnel en couleur [47]. Cependant, et dans certaines situations, la classification dans l'espace **RGB** n'est pas adéquate, parce que les composantes de chrominance et de luminance sont mélangées.

Afin d'effectuer une meilleure classification, nous avons développé un nouvel histogramme 2D pour la segmentation d'image couleur dans l'espace **HSV**. Sural [48] a illustré, pour une Intensité et une Teinte données, que si la Saturation est changée de 0 à 1, alors la couleur perçue passe d'une nuance de gris à la forme de couleur la plus pure représentée par sa teinte.

De cette façon, nous transformons l'image **RGB** en image **HSV** et pour tous les pixels résultants, nous utilisons une équation de seuil de Sural [48] pour déduire une image au niveau de gris intermédiaire : pour de faibles valeurs de Saturation, une couleur peut être approchée par une

valeur spécifiée au niveau gris par le niveau d'Intensité, alors que pour une Saturation plus élevée, la couleur peut être approximée par sa valeur de Teinte.

Zhang [49] a présenté un autre type d'histogramme 2D en niveau de gris, pour l'image monochrome, qui diffère de la matrice de co-occurrence au niveau de gris. Il est formé par le produit cartésien de la valeur minimale en niveau de gris dans les 4 zones de voisinage et la valeur maximale en niveau de gris dans la matrice de voisinage 3×3 , à l'exception des pixels des 4 voisins. Sur la base de la description ci-dessus, nous avons construit l'histogramme 2D [47].

Les pics formés représentent des classes, un pic est marqué comme significatif s'il représente une population supérieure ou égale à un seuil S_0 (exprimé en pourcentage du nombre total de pixels dans l'image). L'algorithme de segmentation est effectué par la re-classification des pixels qui ne sont pas classés dans les classes déterminées en fonction de la distance de Mahalanobis.

3.2.2 Les données de l'image QuickBird

La zone d'intérêt utilisée dans ce travail est une zone urbaine, délimitée entre la longitude $\phi_1 = -6^\circ 96' 41.97'' W$ et la latitude $\lambda_1 = 33^\circ 92' 86.85'' N$ et la longitude $\phi_2 = -6^\circ 95' 17.97'' W$ et la latitude $\lambda_2 = 33^\circ 91' 52.59'' N$. La figure 3.1 montre la composition des couleurs **RGB** de l'image et la variété des unités de la couverture du sol et de l'utilisation du sol existant dans cette zone est évidente.



FIGURE 3.1 – © Digital Globe : Zone d'intérêt de l'image *RGB*.

3.3 Méthode de classification

3.3.1 Construction de l'histogramme 2D

L'objectif est de fusionner en deux classes (objet et fond) les pixels qui présentent des caractéristiques colorimétriques similaires dans l'image couleur, d'une manière non supervisée. L'algorithme de l'histogramme 2D fonctionne à partir de l'une des trois composantes de l'image couleur.

L'histogramme 2D d'une image en couleur I est présenté par $p(x_1, x_2)$, le nombre de pixels dans I présentant les composantes colorimétriques (x_1, x_2) .

Puisque chaque axe colorimétrique de $\mathbf{I}$ est quantifié sur 256 niveaux, l'histogramme 2D peut être représenté par une image $\mathbf{J}$ dont la résolution spatiale est égale à **256X256**. La valeur $\mathbf{pn}(\mathbf{x}_1, \mathbf{x}_2)$, du pixel de coordonnées $(\mathbf{x}_1, \mathbf{x}_2)$, dans $\mathbf{J}$ est obtenue par une contraction dynamique linéaire de l'histogramme entre **1** et $M = \mathbf{min}(p_{max}; 255)$:

$$\mathbf{pn}(\mathbf{x}_1, \mathbf{x}_2) = \mathbf{round}\left[\frac{(M - 1)p(\mathbf{x}_1, \mathbf{x}_2) - Mp_{min} + p_{max}}{p_{max} - p_{min}}\right] \quad (3.1)$$

Où p_{min} et p_{max} sont respectivement les valeurs minimale et maximale de p . Grâce à cette représentation, l'analyse de l'histogramme 2D peut être réalisée avec les outils développés pour les images de niveaux de gris de 8 bits.

Avant de normaliser l'histogramme pour constituer l'image J, un filtrage est nécessaire pour lisser ce dernier en supprimant les petits extrema locaux. Un filtre gaussien bidimensionnel est utilisé [50] :

$$G(x, y) = \frac{1}{\sqrt{2\pi}\sigma} e^{\left(-\frac{x^2 + y^2}{2\sigma^2}\right)} \quad (3.2)$$

Comme la taille du masque de convolution est $[-2K + 1, 2K + 1]$, presque la quasi totalité (99,9%0) de la surface sous la courbe gauss sera prise en compte en posant [50] :

$$\sigma = \frac{2K + 1}{6} \quad (3.3)$$

Cependant, elle ne peut être considérée comme gaussienne que pour des valeurs de K suffisamment élevées.

3.3.2 Analyse hiérarchique de l'histogramme 2D

Clément et al. [39, 40] ont proposé une décomposition hiérarchique de l'histogramme 2D, cette procédure est une version de l'algorithme de remplissage classique proposé par Vincent et Soille [43].

Elle consiste en une décomposition hiérarchique des niveaux de gris dans J . Pour chaque niveau de gris p_n , repérant les composantes connectées de J dont les valeurs de pixels sont supérieures ou égales à p_n identifient les pics p_i . Chaque pic est ensuite décomposé itérativement en pics plus étroits, du niveau de gris 0 au niveau de gris 255. Un pic est marqué comme significatif s'il représente une population supérieure ou égale à un seuil S . Ce seuil est exprimé en pourcentage du nombre de pixels correspondants dans l'image I . La procédure est illustrée sur la figure 3.2 (dessiné dans une dimension pour plus de clarté).




FIGURE 3.2 – Un exemple de décomposition hiérarchique [31].

Les feuilles entourées d'un cercle rouge (partie (b)) correspondent aux pics reconnus à la fin de la décomposition itérative (lignes pleines dans la partie (a)), tandis que les feuilles marquées par $\ll \mathbf{S} \gg$ (partie (b)) correspondent à des pics insignifiants ou non retenus à cause d'un effectif inférieur au seuil $\mathbf{S}$ (lignes pointillées dans la partie (a)).

Nous appellerons les noyaux $\mathbf{K}_i$ pics correspondant aux feuilles encadrées sur la droite de la figure 3.2. En d'autres termes, les noyaux sont des pics significatifs (partie (a) de la figure 3.2) sans descendants dans l'arbre de décomposition hiérarchique (partie (b) de la figure 3.2) (par exemple, la figure 3.2 montre cinq pics significatifs $\mathbf{p}_i (i = 0 - 4)$ et Trois noyaux $\mathbf{K}_i (i = 2, 3, 4)$. Le nombre de classes $\mathbf{N}_c$ est pris égal au nombre de noyaux (la classe correspondante au noyau $\mathbf{K}_i$ est notée $\mathbf{C}_i$). Par conséquent, $\mathbf{N}_c$ dépend du seuil $\mathbf{S}$, c'est-à-dire de la précision avec laquelle l'image est analysée. Cependant, la méthode reste opérationnelle au-delà du simple cas de deux classes bien distinctes : dès qu'une classe présente plusieurs sous-pics dans l'histogramme 2D, elle peut être subdivisée en sous-classes tout en redressant le seuil $\mathbf{S}$. Ceci est illustré dans la Figure 3.2, où la classe initiale, étiquetée **1**, est divisée en deux classes (étiquetées **3** et **4**) en raison du choix du seuil. Une valeur inférieure au seuil $\mathbf{S}$ fournirait une troisième sous-classe.

3.3.3 Distance

Une deuxième étape est incorporée à l'algorithme pour le reclassement des pixels à une distance. Dans cet ordre, le centre de masse $\boldsymbol{\mu}(\mathbf{K}_i)$ de chaque noyau $\mathbf{K}_i$ peut être calculé dans l'espace 2D. Nous créons par $\boldsymbol{\beta}$ le niveau de gris correspondant au point de coordonnées $(\mathbf{x}_1, \mathbf{x}_2)$ dans l'espace 2D. Deux cas se produisent :

- si $(\mathbf{x}_1, \mathbf{x}_2)$ appartient à $\mathbf{K}_i$, le degré de gris β est attribué à la classe $\mathbf{C}_i$,
- dans le cas contraire, concevons par $\mathbf{P}_k$ le pic $(\mathbf{x}_1, \mathbf{x}_2)$, appartient au niveau de gris β est attribuée à la classe $\mathbf{C}_i$, correspondant au noyau $\mathbf{K}_i$, fils de $\mathbf{P}_k$, tel que $d[\mu(\mathbf{K}_i, (\mathbf{x}_1, \mathbf{x}_2))]$, est minimum, où $d[\mathbf{a}, \mathbf{b}]$ est la distance entre $\mathbf{a}$ et $\mathbf{b}$.

La mesure de distance pour les caractéristiques est d'une importance critique pour toutes sortes de méthodes de classification. D'une manière générale, la distance entre $\mathbf{a}$ et $\mathbf{b}$ séparés a pour expression :

$$dist^2 = (\beta - \mu_i)^t M (\beta - \mu_i) \quad (3.4)$$

Où :

$\mathbf{M}$ est la matrice définissant la métrique.

$\mathbf{T}$ est l'opérateur métrique de transposition.

De nombreux choix de métriques sont possibles, mais le choix d'une métrique peut être considéré comme l'un des paramètres pertinents de l'algorithme proposé. Dans notre travail, nous avons utilisé une métrique simple et bien connue : les métriques de Mahalanobis.

La distance de Mahalanobis est l'une des techniques fondamentales et largement utilisées comme mesure de distance pour la classification [51]. Cette méthode est un classificateur de distance sensible à l'orientation, qui conserve des statistiques uniques pour chaque classe. Elle est définie en posant $\mathbf{M} = \mathbf{C}\mathbf{v} - \mathbf{1}$, où $\mathbf{C}\mathbf{v} - \mathbf{1}$ qui représente l'inverse de la matrice de covariance

de la classe C_i . La distance de Mahalanobis est donc une distance euclidienne pondérée, où la pondération est déterminée par la plage de variabilité des points d'échantillonnage. Elle est exprimée par la matrice de covariance. Avec la métrique de Mahalanobis, la frontière entre deux classes C_i et C_j est quadratique, c'est-à-dire une ellipse ou une hyperbole.

Finalement, chaque couleur de l'image segmentée correspond à une classe de l'image originale.

3.4 Résultats et discussion

Les expériences présentées dans ce chapitre concernent la classification des pixels d'image synthétique d'une part et des pixels d'autre part, pour l'utilisation et pour la couverture du sol de notre image QuickBird.

Premièrement, nous avons considéré l'image synthétique utilisée dans différents travaux [28, 52, 53]. Elle contient quatre motifs de différentes formes et couleurs (voir figure 3.3 a). Le motif circulaire contient deux formes qui ne se diffèrent que par la variation de la composante de saturation, y compris le fond, l'image contient alors six classes différentes.

La différence entre deux régions en raison de la variation de saturation est toujours une problématique difficile. Souvent, deux couleurs distinctes sont fusionnées ensemble.

La méthode de segmentation en histogramme 2D utilisant l'espace **RGB** ne parvient pas à séparer les deux formes dans le motif circulaire. A partir

des résultats d'expérimentation portées aux figures 3.3 b et 3.3 c, on distingue clairement que l'approche proposée donne un meilleur regroupement et que le problème de la disparition pour séparer les deux formes est atténué.

A partir de ces résultats, on peut déduire que l'espace **RGB** n'est pas capable de séparer les deux formes dans le motif circulaire. Ceci est dû à la forte corrélation entre les composantes **R**, **G** et **B**, et que la mesure d'une couleur dans l'espace **RGB** ne représente pas des différences de couleur dans une échelle uniforme. Par conséquent, il est impossible d'évaluer la similitude de deux couleurs à partir de leur distance dans l'espace **RGB**. Cependant, dans l'espace **HSV** où les informations de couleur et d'intensité sont séparées, la segmentation des deux formes peut être réalisée par la méthode proposée.

Deuxièmement, nous avons appliqué l'algorithme proposé à la classification de la couverture du sol urbain. En ce qui concerne les histogrammes 2D de l'image qui sont représentés dans la figure 3.4 sont affichés sur la figure 3.7 (le plan **GB** et les histogrammes utilisant l'espace **HSV** respectivement), en utilisant la distance de Mahalanobis. Dans le cas de la figure 3.7 a, l'histogramme présente les classes qui ne correspondent pas à la réalité. Le résultat segmenté par la distance de Mahalanobis dans l'histogramme **GB** est faux (figure 3.4 b) bien qu'il représente quatre classes. Il semble que la classification avec la distance de Mahalanobis des l'histogramme **RG** et **RB** n'est pas d'un grand intérêt pour la segmentation de l'image satellite. Ainsi, nous utiliserons l'histogramme **HSV** pour effectuer la classification.




FIGURE 3.3 – Histogrammes *RG* et *HV* de l'image synthétique dans les espaces *RGB* et *HSV*.

Dans la figure 3.4, une représentation visuelle de la zone sélectionnée pour la classification de la couverture du sol en utilisant chaque approche est représentée. La méthode basée sur l'espace *RGB* présentait des confusions des classes (figure 3.5). Généralement le protocole de classification précédemment étudié a bien réussi à extraire des informations relatives à la couverture et à l'utilisation du sol. L'identification des classes telles que forêt, végétation faible et dense, arbustes, sable, terrain cultivé et non cultivé, eau, carrière, surface ouverte, zone résidentielle, mousse de mer, routes, roches et des zones non classées était assez efficace (figure 3.6).



FIGURE 3.4 – Image QuickBird *RGB*.




FIGURE 3.5 – Résultat d'Histogramme *RG*.






FIGURE 3.6 – Histogramme 2D utilisant l'espace HSV .



(a) Histogramme RB -Espace RGB



(b) Histogramme 2D-Espace HSV

FIGURE 3.7 – Vue de dessus de l'histogramme 2D.

3.5 Conclusions

Dans ce chapitre, nous avons évalué la pertinence des résultats de l'application d'un nouvel algorithme de segmentation d'image numérique couleur (voir [Annexe 1](#)), afin d'estimer la qualité d'images multispectrales du satellite QuickBird dans le domaine d'identification de la couverture et de l'utilisation des sols urbains.

La méthode de segmentation par classification non supervisée est basée sur l'analyse hiérarchique des histogrammes bidimensionnels, ce qui est approprié pour la classification des pixels d'images multispectrales, nous a permis l'amélioration de la qualité de la classification par le reclassement des pixels non classés auparavant par la distance de Mahalanobis.

L'approche proposée a été testée sur des images synthétiques et par la suite a été appliquée à la classification des données QuickBird de la couverture et de l'utilisation du sol urbain de la zone d'étude sélectionnée qui appartient à la préfecture de Skhirate-Témara, Maroc.

Les résultats obtenus par l'histogramme 2D dans l'espace **HSV** se sont avérés plus satisfaisants que ceux obtenus en utilisant l'espace **RGB**.

La méthode proposée semble être très prometteuse et son développement doit être davantage étudié. Pour cela, nous avons l'intention d'introduire d'autres paramètres ; tels que le concept d'entropie, la fonction d'onde et l'optimisation multiobjectifs pour séparer les classes complexes.

Chapitre 4

Segmentation d'images

Satellites de très haute
résolution spatiale

4.1 Introduction

La couverture du sol fait référence aux caractéristiques physiques de la surface de la terre, prélevée dans la répartition de la végétation, de l'eau et d'autres caractéristiques physiques du terrain. L'utilisation du sol se base sur la façon dont la terre a été utilisée par l'être humain et de son habitat [32]. L'identification de couverture et l'utilisation du sol en milieu urbain peut être atteinte par la classification des pixels des images multispectrales, en utilisant la méthode de segmentation. Pour cela, une nouvelle génération de capteurs spatiaux d'imagerie de très haute résolution, comme Ikonos, QuickBird et WorldView, satisfait les grandes attentes pour la télédétection des zones urbaines ; telles que la couverture et l'utilisation du sol urbaine [36].

La segmentation est la technique et le mode opératoire utilisé pour diviser l'image en plusieurs régions sans chevauchement en fonction de leurs caractéristiques. Les valeurs de pixels dans la même région ont des caractéristiques semblables tandis que celles provenant de différentes régions ont des caractéristiques différentes. Ces pixels peuvent être entièrement classés en plusieurs catégories en fonction des caractéristiques dominantes qu'ils emploient, telles que, les méthodes basées sur le contour [38], les méthodes

basées sur la région de culture [28], les méthodes basées sur les réseaux de neurones, les méthodes basées sur la physique [39, 42, 43] et les méthodes basées sur l'histogramme de seuillage [44].

Diverses méthodes ont été mises au point et ont été utilisées avec un succès relatif. Cependant, dans certaines situations pratiques, la résolution des problèmes de segmentation a besoin de plus d'informations que celle qui est contenue dans une seule bande d'image. Dans ce cas, l'utilisation de plusieurs composantes de couleur d'une image multispectrale est nécessaire [31, 39, 40, 54, 55]. Dans la pratique, l'application de telle méthode de segmentation, à des images de très haute résolution spatiale, conduit à des résultats inexacts. Dans certains cas, des régions d'intérêt distinctes se sont classées comme étant homogènes. Ceci est dû à deux questions cruciales pour la segmentation des images couleurs :

- Quelle méthode de segmentation doit-on utiliser ?
- Quel espace de couleur devrait-on adopter ? [36].

Il a été démontré, pour des problèmes de classification non supervisée, que l'histogramme de seuillage est une méthode appropriée pour obtenir de bons résultats de segmentation avec une complexité de calcul faible pour une large classe d'images [36, 39, 40].

En l'occurrence, les algorithmes de classification basés sur l'analyse de l'histogramme 2D, qui est obtenu par la projection d'histogramme multidimensionnel sur deux plans de couleur. Ces algorithmes ont été développés et utilisés avec succès [31, 45, 54, 55, 56, 57, 58, 59].

Pour surmonter ce problème, une nouvelle génération de méthode de segmentation est nécessaire. Nous avons développé deux méthodes de segmentation :

- La première est basée sur l'information de la théorie quantique, où nous avons développé une méthode de segmentation quantique. Cette méthode est liée à une évaluation pratique de l'algorithme appliqué à la classification de l'image satellite, avec très haute résolution spatiale –Image QuickBird–, d'une zone urbaine sélectionnée à Skhirate-Temara (NW du Maroc).

Cette approche est scindée en deux parties. La première consiste à une analyse théorique de la nouvelle méthode de segmentation de l'image couleur, basée sur l'analyse hiérarchique des histogrammes 2D [31, 46, 54, 58], construite à partir de la fonction d'onde d'une particule dans une boîte en 2D. L'algorithme de segmentation est aussi accompli par la reclassification des pixels qui ne sont pas classifiés par la distance euclidienne. La seconde est liée à une évaluation pratique de l'algorithme appliqué à la classification de la couverture et de l'utilisation du sol d'une image de la zone urbaine sélectionnée.

- La seconde méthode est basée sur la fonction d'optimisation multiobjectifs qui met l'accent sur la séparation des différentes classes de niveaux de gris d'une manière optimale ; en fonction de certains critères, en utilisant des techniques typiques de segmentation d'images.

Deux fonctions d'optimisation multiobjectifs ont été développées avec des critères différents à savoir :

- La première fonction -MOBJ2- est basée sur la variance intra-classe modifiée, la probabilité d'erreur globale et l'entropie totale.
- La seconde fonction -MOBJ3- est basée les entropies de Tsallis et de Rényi.

Ces deux fonctions permettent de chercher le centre de gravité pour chaque région de l'image en niveaux de gris et le seuil de son histogramme [31, 54, 55, 56, 57, 58, 59].

Afin de démontrer la faisabilité de chacune des deux méthodes proposées, nous procédons par une comparaison de la première approche par rapport à celles d'Otsu et de K-Means et la deuxième méthode par rapport à la première, et cela à partir des tests sur des images synthétiques d'une part et d'autre part, nous évaluerons chacun des deux algorithmes sur la classification de l'utilisation et de la couverture du sol en utilisant une image satellite de très haute résolution spatiales.

Nous procéderons, au début, par la présentation de l'approche de segmentation multicritère, puis nous décrirons les deux fonctions d'optimisation multiobjectifs, ensuite, nous choisirons des échantillons d'images à utiliser et nous présenterons les critères de Levine et Nazif et le critère de l'erreur quadratique moyenne, et en dernier lieu, nous révélerons les résultats expérimentaux et la discussion.

4.2 Description de la méthode de la fonction d'onde

Dans cette étude, nous assimilons l'image satellite comme une image **RGB**, où chaque composante peut représenter n'importe quelle bande d'images.

4.2.1 Modèle pour la Particule

Dans le modèle de la particule dans une boîte bidimensionnelle (Figure 4.1), on considère une particule confinée à un plan rectangulaire, de longueur L_x dans la direction X et de largeur L_y dans la direction Y.




FIGURE 4.1 – Modèle de la Particule.

L'énergie potentielle est nulle partout dans ce plan, et infinie au niveau des parois et au-delà (Équation 4.1).

$$V(x, y) = \begin{cases} 0 & \text{pour } 0 < x < L_x \text{ et } 0 < y < L_y \\ \infty & \text{ailleurs} \end{cases} \quad (4.1)$$

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 :

$$\frac{-\hbar^2}{2m} \left(\frac{\partial^2 \Psi}{\partial x^2} + \frac{\partial^2 \Psi}{\partial y^2} \right) = E \Psi(x, y) \quad (4.2)$$

Où :

$\hbar$ est la constant de Planck réduite, $\hbar^2 = \frac{h}{2\pi}$,

h est la constante de Planck = $6,62607015 \cdot 10^{(-34)} m^2 \text{ kg/s}$,

m est la masse de la particule, et

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 considérée comme une particule dans une boîte unidimensionnelle, de sorte que nous pouvons immédiatement noter les solutions suivantes :

$$\Psi_{n_x}(x) = \sqrt{\frac{2}{L_x}} \sin\left(\frac{n_x \pi x}{L_x}\right) \quad (4.3)$$

$$\Psi_{n_y}(y) = \sqrt{\frac{2}{L_y}} \sin\left(\frac{n_y \pi y}{L_y}\right) \quad (4.4)$$

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 : $|\psi|^2$.

4.2.2 Modèle pour l'Image Satellite

Selon l'approche quantique, nous associons à chaque pixel de la composante image une fonction de trois ondes selon les différents plans d'image (R, G et B) (voir figure 4.2) Cette fonction d'onde évolue selon l'équation stationnaire de Schrödinger :

$$\Psi_{n_x}(r) = \sqrt{\frac{2}{N_C}} \sin\left(\frac{n_x \pi r}{N_C}\right) \quad (4.5)$$

$$\Psi_{n_y}(g) = \sqrt{\frac{2}{N_L}} \sin\left(\frac{n_y \pi g}{N_L}\right) \quad (4.6)$$

$$\Psi_{n_x}(b) = \sqrt{\frac{2}{N_C}} \sin\left(\frac{n_x \pi b}{N_C}\right) \quad (4.7)$$

Où :

N_C est le nombre de colonnes,

N_L est le nombre de lignes,

r, g et b sont les valeurs de pixel respectivement dans le plan R, G et B de l'image.

Nous appliquons cette technique sur l'image en niveaux de gris et l'image couleur dans l'espace RGB . De cette façon, nous construisons l'histogramme 2D en utilisant la fonction d'onde ψ et la densité de probabilité $|\psi|^2$.

D'une manière non supervisée, l'objectif est de fusionner en différentes classes les pixels qui présentent une fonction d'onde semblable dans l'image couleur. L'algorithme fonctionne à partir de l'un des trois histogrammes 2D de l'image couleur $(\psi(r), \psi(g))$ ou $(\psi(r), \psi(b))$ ou $(\psi(b), \psi(g))$.




FIGURE 4.2 – Modèle d'image satellite.

Un histogramme 2D d'une image couleur I cartographie $P(\psi_x, \psi_y)$, c'est le nombre de pixels de l'image I présentant la fonction d'onde (ψ_x, ψ_y) . Chaque axe de la fonction d'onde de l'image I est quantifié sur **256** niveaux, l'histogramme 2D peut être représenté par une image J dont la résolution spatiale est égale à **256X256**. La valeur $P(\psi_x, \psi_y)$ du pixel des coordonnées (ψ_x, ψ_y) dans J est obtenue par une contraction dynamique linéaire de l'histogramme entre **1** et $M = \min(p_{max}, 255)$:

$$P_n(x_1, x_2) = \text{round}\left[\frac{(M - 1)p(x_1, x_2) - Mp_{max} + p_{min}}{p_{max} - p_{min}}\right] \quad (4.8)$$

Où : p_{max} et p_{min} sont respectivement la valeur minimale et la valeur maximale de P .

4.2.3 Méthode de classification

Dans cette étape, nous utilisons l'algorithme de classification proposé par Clément [39, 40] pour détecter les pics qui représentent évidemment les classes. Cette procédure est une version de l'algorithme de remplissage d'eau classique proposé par Vincent [43]. Un pic est considéré comme significatif s'il représente une population supérieure ou égale à un seuil d_0 (exprimé en pourcentage de la population totale en image).

Enfin, nous effectuerons l'algorithme de segmentation par la reclassification des pixels qui n'ont pas été classés auparavant dans des classes déterminées, selon la distance euclidienne, pour l'exécuter à la fin.

4.2.4 Fonction d'évaluation de Borsotti $Q(I)$

Dans la littérature, plusieurs critères ont été développés afin d'aboutir à une évaluation quantitative de la qualité d'une segmentation. Ces critères sont tous basés sur une mesure de l'uniformité en intensité ou en couleur

intra-région et du contraste inter-régions. Une pondération par le cardinal de la région est opérée. Parmi tous les critères disponibles, celui proposé par Borsotti et al. [60] a été retenu puisque d'après les auteurs, ce critère permet d'aboutir à des résultats qui sont plus en adéquation avec notre perception visuelle. Ce critère est défini par :

$$Q(I) = \frac{1}{10000 N} \sqrt{R} \sum_{i=1}^R \left(\frac{e_i^2}{1 + \log N_i} + \frac{R(N_i)^2}{N_i^2} \right) \quad (4.9)$$

Où : I est l'image segmentée,

N est la taille de l'image et $\frac{1}{10000 N}$ est le facteur d'agrandissement,

R est le nombre de régions de l'image segmentée,

N_i est la surface de la $i^{ème}$ région,

$R(N_i)$ est le nombre de régions ayant une surface égale à N_i ,

e_i est l'erreur moyenne des couleurs de la $i^{ème}$ région, qui est définie comme la somme des distances euclidiennes entre les vecteurs de couleur RGB des pixels de la $i^{ème}$ région et le vecteur de couleurs attribué à la $i^{ème}$ région de l'image segmentée.

Les améliorations apportées dans cette nouvelle métrique se manifestent dans la fusion de deux termes :

- le premier terme pénalise les régions non homogènes c'est-à-dire les régions deviennent non homogènes en général quand le nombre de régions dans l'image segmentée diminue,
- le second terme pénalise la sur-segmentation de plusieurs régions ayant des tailles similaires.

Ce critère permet ainsi de pénaliser les segmentations contenant un grand nombre de régions ou contenant des régions hétérogènes d'un point de vue colorimétrique. Notons que plus la valeur de cette métrique est faible, plus la

segmentation est meilleure.

4.2.5 Données d'images multispectrales



FIGURE 4.3 – QuickBird *RGB* Image– Zone d'étude sélectionnée.

L'image retenue pour ce chapitre correspond à la figure 4.3, c'est une image multispectrale couleur, elle est composée par les bandes *RGB* respectivement dont la résolution spatiale est de **2.4m** x **2.4m** et qui représente une zone variée de la préfecture de Skhirate-Témara.

4.2.6 Résultats et discussion

Les expériences présentées dans ce chapitre concernent la classification des pixels des images synthétiques pour ajuster l'algorithme (voir [Annexe 2](#)) développé et par la suite, elle est appliquée à des images QuickBird en niveaux

(a) Image originale (b) Image segmentée




FIGURE 4.4 – Image des carrés synthétiques (465 X 386).

de gris et en couleurs : elles sont des images multispectrales de très haute résolution spatiale et représentent les différentes classes de la couverture et de l'utilisation du sol.

Pour évaluer la technique proposée, nous avons tout d'abord sélectionné l'image des carrés synthétiques (465 X 386). C'est une image qui se compose de quatre couleurs, à partir des résultats obtenus, on peut considérer facilement la performance de notre algorithme développé sur la figure 4.4. Il nous reste donc à approuver cet algorithme, mais cette fois-ci, avec les images satellites et évidemment, nous allons l'accomplir par l'image en niveaux de gris.

4.2.6.1 Image aux niveaux de gris

Nous avons appliqué l'algorithme proposé à la classification de la couverture du sol urbain. Les résultats obtenus par la méthode $|\psi|^2$ pour l'image en niveaux de gris sont présentés dans la figure suivante (Figure 4.5). Enfin, pour évaluer la technique proposée, nous avons utilisé la fonction d'évaluation de Borsotti Q (équation 4.9). Et d'après les résultats du tableau (Table 4.1) et de l'image segmentée (Figure 4.6), on distingue clairement que la méthode proposée fonctionne mieux que l'analyse hiérarchique des histogrammes de

couleur 2D en utilisant l'espace *RGB*.



FIGURE 4.5 – Image aux niveaux de gris.




FIGURE 4.6 – Image segmentée utilisant la méthode proposée.

Image en niveaux de gris	
Histogramme 2D utilisant	Valeur du Coefficient Q
la fonction d'onde ψ	522.9024
la probabilité $ \psi ^2$	271.1887

TABLE 4.1 – Valeurs du Coefficient Q pour ψ et $|\psi|^2$ -Image aux niveaux de gris-.

4.2.6.2 Image couleur

La figure 4.7 c'est l'image originale dans l'espace de couleur **RGB**. Les figures suivantes : Figure 4.8, Figure 4.9 et Figure 4.10 présentent les meilleurs résultats de segmentation d'image couleur tandis ce que le tableau 4.2 présente les valeurs de la fonction d'évaluation de Borsotti Q afin de comparer les méthodes de segmentation :

Pour la segmentation basée sur l'histogramme bidimensionnel dans l'espace **RGB** des trois plans (**RG**, **RB** et **GB**), le coefficient Q le plus petit correspond au plan **RG** qui est égale à **434.6381**, la figure 4.8 présente le résultat correspondant au plan **RB**.

Le plan **RG** représente une meilleure segmentation qui est basée sur l'histogramme 2D construit par ψ , dont la valeur de Q est **637.0482** et la figure 4.9 c correspondante au résultat de cette segmentation dans l'espace **RGB**.

Image couleur			
Histogramme 2D utilisant	Valeur du Coefficient Q		
	Plan RG	Plan RB	Plan GB
la fonction d'onde ψ	637.0482	696.3135	1192.9
la probabilité $ \psi ^2$	305.5231	249.0161	505.8211
l'espace RGB	824.8514	434.6381	660.6642

TABLE 4.2 – Valeurs du Coefficient Q pour ψ , $|\psi|^2$ dans l'espace **RGB**.



FIGURE 4.7 – Image couleur originale *RGB*.




FIGURE 4.8 – Image Segmentée utilisant l'histogramme *RB* dans l'espace *RGB*.




FIGURE 4.9 – Image segmentée utilisant l'histogramme $\mathbf{RG}$ construit par ψ .




FIGURE 4.10 – Image segmentée utilisant l'histogramme $\mathbf{RB}$ construit par $|\psi|^2$.

On remarque que la segmentation basée sur l'histogramme 2D construit par $|\psi|^2$ est la meilleure par rapport aux autres techniques et les tableaux (Table 4.1 et Table 4.2) montrent que les valeurs du coefficient Q calculées pour les différentes méthodes, appliquées aux images en niveaux de gris et aux images couleurs. D'ailleurs, on distingue que toutes du coefficient Q sont inférieures sur tous les plans.

4.3 Description de la méthode d'optimisation multiobjectifs

L'optimisation multiobjectifs s'étend de la théorie d'optimisation en permettant à des objectifs de conception de s'optimiser simultanément. Le problème d'optimisation multiobjectifs se résout de la même façon qu'un problème classique à simple objectif. Le but est de trouver un ensemble de valeurs pour les variables de conception qui optimise simultanément plusieurs fonctions objectifs. En général, la solution obtenue par l'optimisation de chaque objectif séparé ne représente pas une solution possible au problème de l'optimisation multiobjectifs.

Dans la plupart des cas, l'approche proposée dans [61] est justifiée par la simple raison que le processus de segmentation basé sur l'optimisation d'un seul critère ne fonctionne pas parfaitement pour l'ensemble des images. Généralement, la valeur optimale du seuil pour chaque critère ne parvient pas à satisfaire la segmentation d'image. Dans ce cas, nous proposons des seuils optimaux qui permettent l'optimisation d'un ensemble de critères.

Notre objectif est d'amplifier les informations sur la position du seuil optimal qui nous permettra d'obtenir une meilleure segmentation.

Dans ce paragraphe, nous présenterons les différents critères que nous allons réduire plus tard pour le processus du seuillage, de l'image, à plusieurs seuils. Nous allons illustrer les deux algorithmes développés avec des critères différents à savoir :

- Le premier algorithme : la variance intra-classe modifiée, la probabilité d'erreur globale et l'entropie totale.
- Le second algorithme : l'entropie de Tsallis et l'entropie de Rényi.

4.3.1 Le critère de la variance intra-classe

Le seuillage basé sur la variance intra-classe a tendance à classer une image dont l'objet et l'arrière-plan sont de tailles similaires. Afin de remédier à cet inconvénient, une fonction objectif est dérivée du critère classique de la variance intra-classe; certaines connaissances sont introduites portant 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 à intégrer les critères pour avoir la propriété de segmentation idéale. Le critère de la variance intra-classe c'est le critère qui exprime l'uniformité et l'homogénéité des régions et il est défini comme suit :

$$MVar(I) = \alpha \sum_{j=1}^{NR} \frac{Var(j)^2}{\beta_j} + \gamma_j \quad (4.10)$$

Nous supposons que le nombre de régions est de deux ($NR = 2$).

α est donnée par $\frac{1}{10000XM} \sqrt{NR}$ où M est la taille de l'image I .

$\beta_j = \frac{1}{1+Log(N_j)}$, N_j désigne le nombre de pixels dans la région J .

$\gamma_j = \frac{R(N_j)^2}{N_j}$, $R(N_j)$ est le nombre de régions dont le cardinal est égal à N_j .

$Var(j)$ est défini comme :

$$Var(R) = \sum_{j=1}^J P_j (m_j - m_G)^2 \quad (4.11)$$

Avec :

$$m_j = \frac{1}{P_j} \sum_{i \in C_j} i p_i$$

$$p_j = \sum_{i \in C_j} p_i$$

$$m_G = \sum_{i=0}^{L-1} i p_i$$

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

j est le nombre de régions,

P_j est la probabilité de la classe j ,

m_j signifie l'intensité des pixels de la classe j ,

m_G est la moyenne globale,

P_i est la fonction de densité de probabilité des différents pixels de l'image,

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

L est le nombre total de niveaux de gris.

4.3.2 Le critère de la probabilité d'erreur globale

Nous supposons que l'histogramme est correctement mis en place en utilisant la fonction de densité de probabilité d'ajustement gaussien. Ensuite, le seuil optimal est déterminé en minimisant la probabilité d'erreur globale. Pour deux fonctions de densité de probabilité gaussienne successive la fonction est donnée par :

$$e(T_i) = P_i \int_{-\infty}^{T_i} P_i(x) dx + P_{i+1} \int_{T_i}^{+\infty} P_{i+1}(x) dx \quad (4.12)$$

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

Donc, la probabilité globale à minimiser est :

$$E(T) = \sum_{i=1}^{d-1} e(T_i) \quad (4.13)$$

Où T est le vecteur de seuils : $0 < T_1 < T_2 < \dots < T_{d-1} < 255$.

4.3.3 Le critère de l'Entropie Totale

Les entropies de deux classes A et B sont définis par :

$$E_{TP_A}(t) = - \sum_{i=1}^t \frac{p_i}{p_t} \log \frac{p_i}{p_t}$$

$$E_{TP_B}(t) = - \sum_{i=t+1}^L \frac{p_i}{1 - p_t} \log \frac{p_i}{1 - p_t}$$

L'entropie totale est :

$$E_{TP_T}(t) = E_{TP_A}(t) + E_{TP_B}(t)$$

Le premier problème de cette approche qui est mise en évidence par Pal et al [62] est que l'entropie de Shannon n'est pas définie pour des densités de probabilité, y compris zéro probabilité. Ensuite, ils ont proposé une nouvelle définition de l'entropie en fonction des informations de gain exponentiel :

$$E_{TP_T}(t) = - \sum_{i=1}^t \frac{p_i}{p_t} e^{1 - \frac{p_i}{p_t}} - \sum_{i=t+1}^L \frac{p_i}{1 - p_t} e^{1 - \frac{p_i}{1 - p_t}} \quad (4.14)$$

4.3.4 Le critère d'Entropie de Tsallis

Tsallis a proposé une nouvelle forme d'entropie basée sur la généralisation en un paramètre de l'entropie de Boltzmann-Gibbs-Shannon [43], connue sous le nom d'entropie de Tsallis. Qu'il l'a défini comme suit :

$$S_q = \frac{1 - \sum_{i=1}^k (p_i)^q}{q - 1} \quad (4.15)$$

Où k est le nombre total de possibilités du système et q est le nombre réel désignant l'indice entropique, qui caractérise le degré du non extensivité.

Dans le cas d'une image définie par K niveaux de gris, soit $p_i = p_1, p_2, \dots, p_k$ la distribution de probabilité des niveaux. Pour les niveaux de gris t , un seuil à deux niveaux est supposé. Dans [44] deux classes ont été introduites, A et B , et leurs distributions de probabilité sont données par :

$$ClasseA : \frac{p_1}{p_A}, \frac{p_2}{p_A}, \dots, \frac{p_t}{p_A} \quad (4.16)$$

$$ClasseB : \frac{p_{t+1}}{p_B}, \frac{p_{t+2}}{p_B}, \dots, \frac{p_k}{p_B} \quad (4.17)$$

Où

$$P_A = \sum_{i=1}^t (p_i) \text{ et } P_B = \sum_{i=t+1}^k (p_i) \quad (4.18)$$

A priori, l'entropie de Tsallis pour chaque distribution est définie par :

$$S_q^A = \frac{1 - \sum_{i=1}^t \left(\frac{p_i}{p_A}\right)^q}{q - 1} \quad (4.19)$$

$$S_q^B = \frac{1 - \sum_{i=t+1}^k \left(\frac{p_i}{p_B}\right)^q}{q - 1} \quad (4.20)$$

Où $S_q(t)$ représente l'entropie de Tsallis pour chaque classe individuelle dépendant du seuil t . L'entropie totale de Tsallis de l'image est écrite comme suit [48] :

$$S_q(t) = S_q^A(t) + S_q^B(t) + (1 - q) \times S_q^A(t) \times S_q^B(t) \quad (4.21)$$

En vision par ordinateur et en traitement d'images, la transformation d'une image de niveau de gris en une image binaire obtenue grâce à un seuillage d'image basé sur le clustering. Reprenons une image en échelle de gris k , avec une distribution de probabilités, $p_i = p_1, p_2, \dots, p_K$. Supposons quelques seuils $t_1, t_2, \dots, t_m$ pour les niveaux de gris. Certaines classes devraient être introduites, d'après Sparavigna [63, 64], leurs distributions de probabilité sont comme suit :

$$(1) : \frac{p_1}{p_1}, \frac{p_2}{p_1}, \dots, \frac{p_{t_1}}{p_1} \quad (4.22)$$

$$(2) : \frac{p_{t_1+1}}{p_2}, \frac{p_{t_1+2}}{p_2}, \dots, \frac{p_{t_2}}{p_2} \quad (4.23)$$

...

$$(m) : \frac{p_{t_{m-1}+1}}{p_m}, \frac{p_{t_{m-1}+2}}{p_m}, \dots, \frac{p_{t_m}}{p_m} \quad (4.24)$$

$$(m+1) : \frac{p_{t_m+1}}{p_{m+1}}, \frac{p_{t_m+2}}{p_{m+1}}, \dots, \frac{p_{t_{m+1}}}{p_{m+1}} \quad (4.25)$$

Donc, l'équation 4.15 devient :

$$\begin{aligned} S_q &= S_q^1 + S_q^2 + \dots + S_q^m + (1 - q) \frac{1}{2} \sum_{i,j=1, i \neq j}^{m+1} S_q^i S_q^j \\ &+ (1 - q)^2 \frac{1}{6} \sum_{i,j,k=1, i \neq j \neq k}^{m+1} S_q^i S_q^j S_q^k + \dots + (1 - q)^m S_q^1 S_q^2 \dots S_q^{m+1} \end{aligned} \quad (4.26)$$

4.3.5 Le critère d'Entropie de Rényi

Nous prenons en compte les limites de la mesure de Shannon dans certaines situations; Rényi [45] a fait le premier pas et a généralisé la mesure de Shannon. Pour remédier à la faiblesse de la mesure de Shannon dans certaines situations, l'entropie de Rényi a franchi l'étape principale et a proposé une mesure paramétrique de l'information.

Dans la littérature, les applications de l'entropie de Rényi couvrent plusieurs domaines allant de la biologie à la médecine, en passant par la génétique, la linguistique et l'économie, le génie électrique, l'informatique, la géophysique, la chimie et la physique [31]. La mesure de l'entropie de Rényi de l'ordre α d'un image définie comme [31, 47] :

$$H_{\alpha}(P) = \frac{1}{1 - \alpha} \ln \sum_{i=1}^k (p_i)^{\alpha} \quad (4.27)$$

Où α est un paramètre réel positif et $\alpha \neq 1$. Depuis l'entropie de Shannon, la mesure est un cas singulier de l'entropie de Rényi pour $\alpha \rightarrow 1$. Soit $p_i = p_1, p_2, \dots, p_k$ la distribution de probabilité pour une image en niveaux de gris.

A partir de cette distribution, nous développons deux distributions de probabilités, la première pour l'objet (classe A) et la seconde pour le fond (classe B), sont données par :

$$(classeA) : \frac{p_1}{p_A}, \frac{p_2}{p_A}, \dots, \frac{p_t}{p_A} \quad (4.28)$$

$$(classeB) : \frac{p_{t+1}}{p_B}, \frac{p_{t+2}}{p_B}, \dots, \frac{p_k}{p_B} \quad (4.29)$$

Où

$$P_A = \sum_{i=1}^t (p_i) \text{ et } P_B = \sum_{i=t+1}^k (p_i) = 1 - P_A \quad (4.30)$$

L'entropie de Rényi pour chaque distribution d'ordre α est définie comme :

$$H_{\alpha}^A(t) = \frac{1}{1-\alpha} \ln \sum_{i=1}^t \left(\frac{p_i}{P_A}\right)^{\alpha} \quad (4.31)$$

$$H_{\alpha}^B(t) = \frac{1}{1-\alpha} \ln \sum_{i=t+1}^k \left(\frac{p_i}{P_B}\right)^{\alpha} \quad (4.32)$$

$H_{\alpha}(t)$ dépend paramétriquement de la valeur du seuil t pour l'objet et pour l'arrière-plan, et écrit comme suit :

$$H_{\alpha}(t) = H_{\alpha}^A(t) + H_{\alpha}^B(t) \quad (4.33)$$

Pour une image, la distribution totale est divisée en N nombre de classes $C = (C_1, C_2, C_3, \dots, C_N)$. Puis priori de Rényi pour chaque distribution définie dans [45] :

$$H_{\alpha}(C_1) = \frac{1}{1-\alpha} \ln \sum_{i=1}^{t_1} \left(\frac{p_i}{P_{(C_1)}}\right)^{\alpha} \quad (4.34)$$

$$H_{\alpha}(C_2) = \frac{1}{1-\alpha} \ln \sum_{i=t_1+1}^{t_2} \left(\frac{p_i}{P_{(C_2)}}\right)^{\alpha} \quad (4.35)$$

...

$$H_{\alpha}(C_N) = \frac{1}{1-\alpha} \ln \sum_{i=t_{N-1}}^{L-1} \left(\frac{p_i}{P_{(C_N)}}\right)^{\alpha} \quad (4.36)$$

Avec :

$$P(C_1) = \sum_{i=1}^t p_i, P(C_2) = \sum_{i=t+1}^{t_2} p_i, \dots, P(C_N) = \sum_{i=t_{N-1}}^{L-1} p_i \quad (4.37)$$

Avec p_i est l'histogramme normalisé et L est l'intensité de gris la plus élevée.

$$H_{\alpha}(t) = H_{\alpha}(C_1) + H_{\alpha}(C_2) + \dots + H_{\alpha}(C_N) \quad (4.38)$$

4.3.6 La Fonction objectif -Objective function-

La fonction d'optimisation multiobjectifs appliquée aux images à deux seuils (images médicales) par Nakib [61], est définie comme suite :

$$MOBJ1(T) = w_1 MV ar(R(T)) + w_2 E(T) \quad (4.39)$$

Où T est le vecteur de seuils : $0 < T_1 < T_2 < \dots < T_{d-1} < 255$.

Et les paramètres de pondération sont donnés par :

$$w_1 = 1 - w_2$$
$$w_2 = \frac{\sum_{i=1}^d \sigma_i^2}{\sigma_{Histogram}^2}$$

Où

d est le nombre de gaussiennes ;

σ_i est l'écart type de la $i^{ème}$ Gaussienne fonction de densité de probabilité *pdf* ;

$\sigma_{Histogram}$ est l'écart-type de l'histogramme d'origine.

Évidemment, cette fonction a été couronnée de succès, mais, elle a montré ses limites. C'est pour cette raison que nous allons améliorer la fonction de Nakib (Équation 4.39) en deux reprises par l'introduction des facteurs d'entropies tels que :

- l'entropie totale donnant naissance à la fonction -MOBJ2- ;
- les entropies de Tsallis et de Rényi donnant naissance à la fonction -MOBJ3-.

4.3.6.1 La Fonction objectif -MOBJ2-

Pour les images à plusieurs seuils, telle que les images panchromatiques, nous proposons de modifier la fonction objective (Équation 4.39) en introduisant l'information sur l'entropie et la fonction objectif équivalente est décrite comme suit :

$$MOBJ2(T) = w_1 MV ar(R(T)) + w_2 E(T) + w_3 E_{TP_T}(T) \quad (4.40)$$

Où T est le vecteur de seuils : $0 < T_1 < T_2 < \dots < T_{d-1} < 255$.

Et les paramètres de pondération sont donnés par :

$$\begin{aligned} w_1 &= 1 - w_2 - w_3 \\ w_2 &= \frac{\sum_{i=1}^d \sigma_i^2}{\sigma_{Histogram}^2} \\ w_3 &= \frac{m_G}{\sum_{j=1}^d j} \end{aligned}$$

Où

d est le nombre de gaussiennes ;

σ_i est l'écart type de la $i^{ème}$ Gaussienne fonction de densité de probabilité *pdf* ;

$\sigma_{Histogram}$ est l'écart-type de l'histogramme d'origine.

j est le nombre de régions,

m_G est la moyenne globale,

Les paramètres de pondération (w_1, w_2 et w_3) permettent de toucher la limite du domaine possible. Cette opération est utilisée lorsque l'objectif de la segmentation consiste à extraire la cible à partir de l'image originale.

4.3.6.2 La Fonction objectif -MOBJ3-

Pour améliorer davantage la fonction d'optimisation multiobjectifs, nous proposons des seuils optimaux qui permettent d'optimiser un ensemble de critères. La méthode de seuillage repose sur les critères d'entropie de Tsallis et d'entropie de Rényi.

En conséquence, pour augmenter la qualité de la segmentation nous proposons de modifier la fonction objectif (Équation 4.39) par le remplacement le critère de la variance intra-classe et le critère de la probabilité d'erreur globale par les critères de l'entropie de Tsallis et l'entropie de Rényi successivement, et la fonction objectif équivalente est décrite comme suit :

$$MOBJ3(T) = w_1 S_q(T) + w_2 H_\alpha(T) \quad (4.41)$$

Où

$S_q(T)$ est l'entropie de Tsallis développée dans la section § 4.3.4 ;

$H_\alpha(T)$ est l'entropie de Rényi développée dans la section § 4.3.5;

Testvecteurdeseuils : 0 ; $T_1 < T_2 < \dots < T_{d-1} < 255$;

w_1 et w_2 sont les coefficients de pondération et sont donnés comme suit :

$$w_1 = 1 - w_2$$

$$w_2 = \frac{\sum_{i=1}^d \sigma_i^2}{\sigma_{Histogram}^2}$$

Avec

d est le nombre de Gaussiens ;

σ_i est la norme d'écart de la $i^{ème}$ fonction de densité de probabilité gaussienne ;

$\sigma_{Histogram}$ est la norme de déviation de l'histogramme d'origine.

L'acceptation de ces deux critères dans l'algorithme de seuil établi par l'introduction de deux paramètres : w_1 et w_2 . Ainsi, w_1 et w_2 sont les paramètres de pondération et permettent d'atteindre la limite du domaine réalisable. Cette opération est utilisée lorsque l'objectif de la segmentation est d'isoler la cible de l'image d'origine.

L'objectif de cette méthode est d'amplifier les informations sur la position du seuil optimal, ce qui nous permet de réaliser une bonne segmentation. Dans cette suite, nous discutons des différents critères que nous maximiserons plus tard pour le processus de seuil d'image à plusieurs niveaux ; comme le critère d'entropie Tsallis et Rényi.

4.3.7 Données d'Images Satellites

Nous allons tester les deux algorithmes sur des images panchromatiques, de très haute résolution spatiale, des satellites QuickBird et Worldview.

4.3.7.1 Image panchromatique - QuickBird -

L'image satellite dédiée à ce travail est une image QuickBird (voir figure 4.11) couvrant une partie de la préfecture de Skhirate-Témara. Cette zone est délimitée par 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 $90Km^2$.

Cette image a été capturée le 15 Juin 2006 à midi. Dans ce chapitre nous avons utilisé seulement la bande panchromatique dont les caractéristiques sont citées dans le tableau 4.3.




FIGURE 4.11 – © Digital Globe : Zone d'étude de l'image Panchromatique QuickBird

Bande	Longueur d'onde (nm)	Résolution Spatial (m)
Panchromatique	450-900 (675)	0.61 x 0.61

TABLE 4.3 – Caractéristiques de l'image Panchromatique (QuickBird 2).

4.3.7.2 Image panchromatique - Worldview -



FIGURE 4.12 – © Digital Globe : Zone d'étude de l'image Panchromatique Worldview

Dans cette partie, nous introduisons l'image panchromatique Worldview (voir figure 4.12), c'est une image archive de très haute résolution spatiale et qui est de **55cm** par pixel (voir tableau 4.4), capturée le 16 Février 2013 à **11h45mn25s**, couvrant une partie de la zone sud du Maroc et délimitée par la longitude $\phi_1 = -13^\circ 35' 62.51''W$ et la latitude $\lambda_1 = 27^\circ 37' 49.30''N$ et longitude $\phi_2 = -13^\circ 31' 04.26''W$ et la latitude $\lambda_2 = 27^\circ 21' 05.41''N$.

Bande	Longueur d'onde (nm)	Résolution Spatial (m)
Panchromatique	450 – 800	0.55 x 0.55

TABLE 4.4 – Caractéristiques de l'image Panchromatique (Worldview).

4.3.8 Critères d'évaluation utilisés

Pour procéder à l'évaluation des algorithmes développés des deux fonction d'optimisation multiobjectifs (MOBJ2 et MOBJ3), nous avons adopté pour les critères d'évaluation suivants :

- les critères de Levine et Nazif :
 - le critère d'uniformité intra région,
 - le critère de disparité inter région et
 - le critère de dissemblance inter intra région.
- le critère de l'erreur moyenne quadratique.

4.3.8.1 Critères de Levine et Nazif

4.3.8.1.1 Critère d'uniformité intra région

Le critère d'uniformité intra région est l'un des critères les plus intuitifs capable de quantifier la qualité du résultat de la segmentation. Weszka et

Rosenfeld [65] proposent un tel critère avec seuillage qui mesure l'effet du bruit pour évaluer certaines images seuillées. Tout en se basant sur la même idée d'uniformité intra région, Levine et Nazif [66] ont également défini un critère qui calcule l'uniformité d'une caractéristique de région basée sur la variance de cette caractéristique :

$$LEV1(I_R) = 1 - \frac{1}{Card(I)} \sum_{k=1}^{N_R} \frac{[\sum_{s \in R_k} g_I(s) - \sum_{t \in R_k} g_I(t)]^2}{[max_{s \in R_k} g_I(s) - min_{s \in R_k} g_I(s)]^2} \quad (4.42)$$

Où

- I_R correspond au résultat de segmentation de l'image dans un ensemble de régions $R = R_1, ..., R_{NR}$ 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 et il peut être généralisé à toute autre caractéristique (couleur, texture,...).

Sezgin et Sankur [67] ont proposé une mesure d'uniformité standardisée. Basée sur le même principe, la mesure de l'homogénéité de Cochran [68] donne une mesure de confiance sur l'homogénéité d'une région. Cependant, cette méthode nécessite une sélection de seuil qui est souvent faite de façon arbitraire, ce qui limite la méthode proposée. Un autre critère pour mesurer l'uniformité intra-région a été développé par Pal et Pal [69]. Il est basé sur un seuillage qui maximise l'entropie locale de second ordre des régions dans le résultat de la segmentation. Dans le cas des images légèrement texturées, les critères d'uniformité intra-région s'avèrent efficaces et très simples à utiliser. Cependant, la présence de textures dans une image génère souvent des résultats inappropriés en raison de l'influence excessive de petites régions.

4.3.8.1.2 Critère de disparité inter région

Complémentaire à l'uniformité intra région, Levine et Nazif [66] ont défini une mesure de disparité entre deux régions pour évaluer la dissimilitude des régions dans un résultat de segmentation. La formule de la disparité totale entre les régions est définie comme suit :

$$LEV2(I_R) = \frac{\sum_{k=1}^{N_R} W_{R_k} \sum_{j=1/R_j \in W(R_k)}^{N_R} \left[\frac{P_{R_k \setminus R_j} |\bar{g}_I(R_k) - \bar{g}_I(R_j)|}{\bar{g}_I(R_k) + \bar{g}_I(R_j)} \right]}{\sum_{k=1}^{N_R} W_{R_k}} \quad (4.43)$$

Comme W_{R_k} est le poids associé à R_k qui peut dépendre de sa zone, par exemple, $\bar{g}_k$ est la moyenne des niveaux 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 . Ce type de critère a l'avantage de pénaliser la sur-segmentation.(Formule intra inter région)

4.3.8.1.3 Critère de dissemblance intra-inter région

Notons que l'uniformité intra région peut être combinée avec la dissemblance inter régions en utilisant la formule suivante :

$$LEV3(I_R) = \frac{1}{2} \left(1 + \frac{1}{C_{N_R}^2 \sum_{i,j=1, i \neq j}^{N_R} \frac{|\bar{g}_I(R_i) - \bar{g}_I(R_j)|}{4} \sum_{i=1}^{N_R} \sigma^2 R_i} \right) \quad (4.44)$$

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

Ce critère [70] combine les disparités intra et inter régions. La disparité intra région est calculée par l'écart-type normalisé des niveaux de gris dans

chaque région. La disparité inter régions calcule la dissemblance du niveau de gris moyen de deux régions dans le résultat de la segmentation.

Haralick et Shapiro [71] considèrent que :

1. Les régions doivent être uniformes et homogènes ;
2. L'intérieur des régions doit être simple sans trop de petits trous ;
3. Les régions adjacentes doivent présenter des valeurs significativement différentes pour les caractéristiques uniformes ;
4. Les contours devraient être lissés et précis.

4.3.8.2 Critère d'erreur moyenne quadratique

Le critère d'erreur quadratique moyenne (MSE) est calculé pixel par pixel en additionnant la différence au carré de tous les pixels et en la divisant par le nombre total de pixels. Le MSE de l'image segmentée peut être calculé en utilisant l'équation donnée par Gobindchandra et al. dans [14] comme ci-dessous :

$$MSE(GI, SI) = \frac{\sum_{i=0} \sum_{j=0} [GI(i, j) - SI(i, j)]^2}{MN} \quad (4.45)$$

Où, M et N sont respectivement le nombre de lignes et de colonnes d'image d'entrée. Alors que GI et SI sont l'image originale et l'image segmentée. MSE doit avoir une valeur inférieure pour avoir une image segmentée de meilleure qualité.

4.3.9 Évaluation des fonctions d'optimisation multiobjectifs développées

4.3.9.1 Évaluation de la fonction MOBJ2

Dans cette section, nous allons comparer notre nouvelle fonction d'optimisation multiobjectifs MOBJ2 à celle de Nakib MOBJ1, en introduisant l'information de l'entropie dans la fonction d'optimisation multiobjectifs et en la testant sur des images synthétiques et des images satellites à haute résolution spatiale. Nous avons pu observer la contribution positive au processus de segmentation. Le résultat de la segmentation est intéressant (figure 4.13), et par conséquent les valeurs d'évaluation obtenus sont maintenues dans le tableau 4.5.





Images Originales		Segmentation par la méthode	
		Multiobjectifs 1	Multiobjectifs 2
Synthétique			
			

FIGURE 4.13 – Segmentation d'images par les deux fonctions d'optimisation multiobjectifs.

Images	Seuil	Filtre	Valeurs des critères d'évaluation de Levine et Nazif					
			<i>Intra région</i>		<i>Inter région</i>		<i>Intra Inter région</i>	
			<i>Maximal</i>		<i>Minimal</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 4.5 – Les valeurs des critères d'évaluation de Levine et Nazif des deux fonctions d'optimisation multiobjectifs (MOBJ1 et MOBJ2).

4.3.9.2 Évaluation de la fonction MOBJ3

Pour évaluer la fonction MOBJ3, nous avons opté pour les deux critères d'évaluation à savoir le critère de Levine et Nazif et le critère de l'erreur quadratique moyenne, afin de remettre en cause la performance de cette méthode par rapport à celle précédemment développée MOBJ2.

Pour chaque zone d'intérêt sélectionnée de l'image Worldview, des seuils optimaux ont été trouvés par les deux critères cités ci-dessus. Les résultats de la segmentation d'image, qui sont illustrés dans le tableau 4.6 et dans la figure 4.14, montrent que la fonction MOBJ3 surmonte les difficultés rencontrées par celle développée précédemment la fonction MOBJ2 et approuvent l'efficacité de la nouvelle méthode.

Par conséquent, l'optimisation multiobjectifs basée sur les entropies de Rényi et Tsallis contribue de manière significative à la performance de la segmentation d'image.

Images	Seuil	Filtre	Critères d'évaluation de Levine et Nazif						Critère d'évaluation	
			Intra région		Inter région		Intra Inter région		Erreur Moyenne	
			Maximal		Minimal		Minimal		Quadratique	
			MOBJ2	MOBJ3	MOBJ2	MOBJ3	MOBJ2	MOBJ3	MOBJ2	MOBJ3
Synthétique	2	1.5	0.0143	0.0421	0.2007	0.1811	0.5493	0.5483	9.4947e+03	9.4334e+03
WorldView	2	1.5	0.0641	0.0693	0.0730	0.0719	0.5340	0.5319	4.3321e+04	4.3261e+04

TABLE 4.6 – Les valeurs des critères d'évaluation des fonctions d'optimisation multiobjectifs (MOBJ2 et MOBJ3).







Images Originales		Segmentation d'images par la fonction	
		Multiobjectifs 2	Multiobjectifs 3
Synthétique			
			

FIGURE 4.14 – Segmentation d'images par MOBJ2 et MOBJ3.

4.3.10 Résultats et discussion

Cas de la fonction MOBJ2

Le seuillage basé sur la variance inter classe a tendance à classer l'image en tant qu'objet; les expériences présentées dans ce travail concernent la segmentation des pixels, des images synthétiques et des images satellites (voir [Annexe 3](#)).

Afin d'évaluer la technique proposée, nous avons utilisé les critères d'évaluation de Levine et Nazif. Nous avons exécuté ces critères sur des images synthétiques. En première phase, nous avons choisi des images qui

contiennent une texture pour étudier l'influence des petites régions. Le résultat de cette expérimentation nous a conduit à la conclusion que les valeurs inter région, intra région et intra inter région de notre méthode proposée sont inférieures à celles fournies par la méthode d'Otsu. Ces mêmes résultats ont été observés lors du traitement d'autres images synthétiques ayant des propriétés morphologiques différentes.

En seconde phase, l'expérimentation a été réalisée sur des échantillon d'images satellites de très haute résolution spatiale (image panchromatique avec une résolution spatiale de **0,61m x 0,61m**). Tout en ajustant le seuil et les coefficients de filtre pour segmenter chaque image. Nous avons également calculé leur centre de gravité ainsi que le critère d'uniformité de Levine et Nazif pour l'intra région, inter région et intra inter région et cela a été fait pour la méthode Multicritère et la méthode Otsu.

Les figures (4.15 et 4.16) présentent respectivement les résultats segmentés pour les images synthétiques et les images panchromatiques et les deux tableaux (4.7 et 4.8) montrent les valeurs numériques des critères d'évaluation calculés pour chaque méthode, nous mènent à distinguer aisément que la méthode proposée fonctionne mieux que celle d'Otsu.

Pour évaluer la qualité des résultats de la segmentation des images satellites, qui contiennent habituellement plusieurs dégradations inconnues, la deuxième phase de cette étude expérimentale comparative a été réalisée et évaluée à l'aide d'une image réelle en niveaux de gris et d'images satellites -ISTHRS-. Nous pouvons déduire, des valeurs obtenues des critères d'évaluation dans les deux tableaux (4.7 et 4.8) qui restent constamment inférieures à celles obtenues en utilisant l'algorithme d'Otsu, que la méthode d'optimisation multiobjectifs

fournit des résultats plus stables et fiables.












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

FIGURE 4.15 – Résultats de la segmentation des images synthétiques.











Images Panchromatiques		Image segmentée par la méthode		
		Otsu	K-Means	Multiobjectifs
Imagesat 1				
Imagesat 2				
Imagesat 3				
Imagesat 4				

FIGURE 4.16 – 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
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 4.7 – Valeurs d'évaluation du critère de Levine et Nazif pour diverses méthodes (Image Synthétiques).

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
ImageSat1	1.66	1.5	0.0612	0.0704	0.0709	0.3747	0.2952	0.2912	0.5556	0.5443	0.5437
ImageSat2	4	3	0.0898	0.0858	0.1286	0.2940	0.3158	0.2901	0.5865	0.5957	0.5789
ImageSat3	4	3	0.1015	0.1002	0.1246	0.3059	0.3355	0.3111	0.5860	0.5975	0.5856
ImageSat4	2.6	1	0.1026	0.0996	0.1338	0.2900	0.3054	0.2826	0.5853	0.5914	0.5796

TABLE 4.8 – Valeurs d'évaluation du critère de Levine et Nazif pour diverses méthodes (Images Panchromatiques).

Cas de la fonction MOBJ3

Le principal objectif de de la fonction d'optimisation multiobjectifs -MOBJ3-, basée sur les entropies de Tsallis et de Rényi, est le reclassement de tous les pixels non classés auparavant par la fonction d'optimisation multiobjectifs -MOBJ2-.






Pour évaluer la fonction MOBJ3, nous avons adopté les deux critères d'évaluation suivants : critères de Levine et Nazif et critères de l'erreur quadratique moyenne, afin de remettre en cause la performance de cette méthode par rapport à celle précédemment développée -MOBJ2-.

Nous avons procédé par une comparaison entre les deux fonctions multiobjectifs MOBJ2 et MOBJ3, pour chaque zone d'intérêt sélectionnée (images synthétiques ou images Worldview), notre algorithme a pu trouver tous les seuils optimaux par les différents critères utilisés. Les figures (4.17 et 4.18) présentent respectivement les résultats segmentés pour les images synthétiques et les images satellites et les deux tableaux (4.9 et 4.10) montrent les valeurs numériques des critères d'évaluation calculés pour chaque méthode. Ainsi que les résultats obtenus par cette approche ont été très satisfaisants et l'efficacité de cette méthode est confirmée.

Les résultats de la fonction d'optimisation multiobjectif -MOBJ3- basée sur les entropies de Rényi et Tsallis nous approuvent son efficacité par rapport à la méthode basée sur -MOBJ2-. Et par conséquent, la nouvelle méthode basée sur l'optimisation multiobjectifs -MOBJ3- contribue de manière significative à la performance.

Images	Seuil	Filtre	critère Intra région de Levine et Nazif		critère Inter région de Levine et Nazif		critère Intra Inter région de Levine et Nazif		Critère de l'Erreur quadratique moyenne	
			MOBJ2	MOBJ3	MOBJ2	MOBJ3	MOBJ2	MOBJ3	MOBJ2	MOBJ3
ImagSyn1	3	3	0.0097	0.0110	0.1555	0.1497	0.5318	0.5295	1.0714e+04	1.0702e+04
ImagSyn2	3	3	0.0023	0.0024	0.1865	0.1835	0.5204	0.5195	2.6643e+03	2.6575e+03
ImagSyn3	0.01	0	0.0043	0.0124	0.3301	0.2495	0.5394	0.5387	5.5009e+03	5.5000e+03
ImagSyn4	4	1	0.0590	0.0760	0.2880	0.2485	0.5398	0.5687	1.1660e+04	1.6568e+04
ImagSyn5	3	0	0.0117	0.0299	0.2187	0.1712	0.5408	0.5397	6.4119e+03	6.3860e+03
ImagSyn6	2	1.5	0.0143	0.0421	0.2007	0.1811	0.5493	0.5483	9.4947e+03	9.4334e+03

TABLE 4.9 – Valeurs d'évaluation des Image Synthétiques

Images Synthétiques		Image segmentée par la méthode	
		MOBJ2	MOBJ3
ImageSynt1			
	Vecteur Seuil	115	110
ImageSynt2			
	Vecteur Seuil	61	56
ImageSynt3			
	Vecteurs Seuls	86 89	73 107















Images Synthétiques		Image segmentée par la méthode	
		MOBJ2	MOBJ3
ImageSynt4			
	Vecteurs Seuils	127 130	88 163
ImageSynt5			
	Vecteurs Seuils	61 64 127	56 69 103
ImageSynt6			
	Vecteurs Seuils	43 113 132	64 97 123

FIGURE 4.17 – Résultats de la segmentation des images synthétiques

Images	Seuil	Filtre	critère Intra région de Levine et Nazif		critère Inter région de Levine et Nazif		critère Intra Inter région de Levine et Nazif		Critère de l'Erreur quadratique moyenne	
			MOBJ2	MOBJ3	MOBJ2	MOBJ3	MOBJ2	MOBJ3	MOBJ2	MOBJ3
ImagSat1	4	1.5	0.1185	0.1309	0.1284	0.1131	0.5354	0.5317	4.2118e+04	4.1987e+04
ImagSat2	3.9	1.5	0.1319	0.1398	0.1619	0.1476	0.5480	0.5411	3.5385e+04	3.5299e+04
ImagSat3	5	1.5	0.2283	0.2288	0.1741	0.1264	0.5315	0.5230	4.3872e+04	4.3730e+04
ImagSat4	4.6	1.5	0.0967	0.0965	0.1268	0.1032	0.5442	0.5385	4.4796e+04	4.4679e+04
ImagSat5	3	0	0.2019	0.2345	0.0938	0.0920	0.5207	0.5195	4.7283e+04	4.7149e+04
ImagSat6	2	1.5	0.0641	0.0693	0.0730	0.0719	0.5340	0.5319	4.3321e+04	4.3261e+04

TABLE 4.10 – Valeurs d'évaluation des Images sentinel

Images Sentinel		Image segmentée par la méthode	
		Multiobjectifs MOBJ2	Multiobjectifs MOBJ3
Imagesat1			
	Vecteurs Seuils	202 253	194 230
Imagesat2			
	Vecteurs Seuils	183 253	177 218
Imagesat3			
	Vecteurs Seuils	195 253	198 226
Imagesat4			
	Vecteurs Seuils	127 130	192 226






Images Sentinel		Image segmentée par la méthode	
		Multiobjectifs MOBJ2	Multiobjectifs MOBJ3
Imagesat5			
	Vecteurs Seuils	208 219 253	200 218 233
Imagesat6			
	Vecteurs Seuils	200 215 253	195 215 233

FIGURE 4.18 – Résultats de la segmentation des images sentinel

4.4 Conclusion

- Dans diverses situations de classification d'image, plusieurs zones fermées sont classés comme homogènes. Cependant, nous avons pensé que la théorie de la mécanique quantique pourrait prendre en compte plus les informations sur le processus de classification des pixels et ce qui va permettre la séparation des différentes zones fermées.

Sur la base de cette théorie (la mécanique quantique), nous avons développé un nouvel algorithme de segmentation pour le seuillage des histogrammes bidimensionnel dans l'espace de couleur **RGB** d'image.

Cet algorithme a été appliqué en premier lieu sur des images synthétiques et en suite sur des images satellites de très haute résolution spatiale, à savoir l'image en niveaux de gris et l'image multispectrale dans l'espace **RGB** de QuickBird.

Une comparaison des résultats de segmentation a eu lieu, d'une part, entre les différents plans dans l'espace de couleur **RGB** et d'autre part, entre cet algorithme utilisé par la fonction d'onde ψ et celui qui utilise la densité de probabilité $|\psi|^2$.

Notre méthode développée pour la classification non supervisée des pixels est très prometteuse. En s'appuyant sur le critère d'évaluation de Borsotti, le résultat obtenu, par cette méthode, est très satisfaisant.

- Nous avons proposé une deuxième méthode de segmentation multicritère basée sur la séparation des différentes classes de niveaux de gris de manière optimale selon certains critères et nous les avons appliquées à des images satellites de très haute résolution spatiale.

La mise en place de l'algorithme de segmentation, qui est basé sur la fonction d'optimisation multiobjectifs -MOBJ2- et qui tient en compte l'information sur l'entropie, passe par les étapes suivantes :

Premièrement, pour chaque région d'intérêt de l'image sélectionnée, nous avons calculé le centre de gravité de leur histogramme-2D.

Deuxièmement, avec la fonction d'optimisation multiobjectifs, nous avons calculé le seuil entre deux centres de gravité voisins par la séparation des différentes classes de niveaux de gris de manière optimale, en fonction de certains critères.

L'évaluation de notre fonction d'optimisation multiobjectifs -MOBJ2- par rapport à celle de Nakib -MOBJ1- passe par une comparaison qui fait appel aux critères d'évaluation de Levine et Nazif et selon l'expérimentation cette méthode a donné de bons résultats.

Ensuite, nous l'avons appliqué à la segmentation des images multi-classes tels que des images synthétiques et des échantillons d'image panchromatique de très haute résolution spatiale. Par la suite, nous l'avons comparée à celles de Otsu et de K-Means qui sont disponibles sur MATLAB.

L'évaluation de cette méthode de segmentation, basée sur les critères d'évaluation de Levine et Nazif, montre que la fonction d'optimisation multiobjectifs développée donne des résultats prometteurs par rapport à ceux obtenus par les méthodes d'Otsu et de K-Means.

- Nous avons proposé en parallèle une nouvelle méthode de segmentation multicritère -MOBJ3- basée sur les entropies de Rényi et de Tsallis et nous l'avons comparé à cette développée précédemment -MOBJ2-.

Les démarches définies auparavant pour la fonction d'optimisation multiobjectifs -MOBJ2- sont les mêmes pour la fonction -MOBJ3- avec les critères d'évaluation suivants : critères de Levine et Nazif et critère de

l'erreur quadratique moyenne.

Nous l'avons appliqué à la segmentation des images multiclassées tels que des images synthétiques et des échantillons d'image de très haute résolution spatiale : image WorldView. Par la suite, nous l'avons comparée à celle développée précédemment -MOBJ2-.

Afin de remettre en cause la performance de cette méthode par rapport à celle précédemment développée -MOBJ2- et pour évaluer la nouvelle méthode de segmentation, nous avons opté pour les critères d'évaluation de Levine et Nazif et le critère de l'erreur quadratique moyenne. Pour chaque zone d'intérêt sélectionnée de l'image Worldview, les seuils optimaux par tous les critères utilisés dans cette étude sont trouvés.

Les résultats obtenus par cette approche ont été très satisfaisants et l'efficacité de cette méthode est confirmée. Cette méthode surmonte les difficultés de la méthode précédemment développée en 2017 et a obtenu des résultats plus précis. Par conséquent, la nouvelle méthode basée sur l'optimisation multiobjectifs contribue de manière significative à la performance.

Conclusion générale

La segmentation d'images constitue une étape très importante dans l'interprétation du contenu d'une scène donnée. Dans cette thèse, nous nous sommes intéressés à la segmentation basée sur les régions des images multispectrales du satellite QuickBird et du satellite WorldView. Ainsi, deux approches de segmentation liées au seuillage des histogrammes 2D ont été proposées :

- La première est basée sur la fonction d'onde appliquée aux images multispectrales.
- La deuxième est basée sur l'optimisation de la fonction multiobjectif, scindée en deux fonctions : –MOBJ2– et –MOBJ3– appliquées respectivement aux images de très haute résolution spatiales du satellite QuickBird et du satellite WorldView.

L'objectif principal visé par ce travail est d'élaborer des techniques de segmentation basées sur les régions, qui prennent en compte l'aspect spectral et local des images multispectrales. Les résultats obtenus par les deux techniques que nous avons élaborés montrent que l'utilisation conjointe de ces deux aspects est d'une importance majeure pour la segmentation d'images multispectrales. Malgré la complexité des détails composant ces images, les différents résultats de segmentation, montrent que les images traitées ont été correctement segmentées.

En effet, pour les images du test utilisées, nous avons employé des critères d'évaluation. Pour le cas de la fonction d'onde, nous avons utilisé la fonction d'évaluation de Borsotti et pour le cas de segmentation basée sur l'optimisation multiobjectif nous avons utilisé les critères de Levine et Nazif et le critère de l'erreur quadratique moyenne.

Nous avons appliqué ces algorithmes aux images multispectrales. Les méthodes que nous avons élaborées ont permis de segmenter correctement les différentes images sélectionnées. Les régions ont été correctement reproduites par les deux techniques, montrant, ainsi, la supériorité de nos méthodes comparées aux techniques usuelles publiées dans la littérature ; telle que celle d'Otsu.

Pour améliorer davantage les algorithmes de segmentation des images multispectrales, il serait intéressant de lancer une réflexion sur la possibilité d'une spécification automatique d'un seuil approprié pour le processus de fusion des régions et d'utiliser les approches par Machine Learning -ML- et de l'Intelligence Artificielle -AI-.

Bibliographie

Bibliographie

- [1] Troya Galvis Andrés, “Approche collaborative et qualité des données et des connaissances en analyse multiparadigme d’images de télédétection”, Thèse de doctorat, Université de Strasbourg, France, 2016.
- [2] Nuzillard D., Lazar C., “Partitional Clustering Techniques for multispectral image segmentation”, Journal of Computers, 2(10), 2007.
- [3] Gruia C., Pop F., Cristea V., “A distributed algorithm for multispectral image segmentation”, Ninth international symposium on symbolic and numeric algorithms for science computing, 353-360, 2007.
- [4] Lillesand T.M., Kiefer R.W. “Remote sensing and image interpretation”, Fourth Edition. WILEY, 2000.
- [5] Notion fondamentales de télédétection, www.nrcan.gc.ca/files/earthsciences/pdf/resource/tutor/fundam/pdf/fundamentals_f.pdf
- [6] Segmentation d’image, <http://e-cours.univ-pqris.fr>
- [7] J. J. Pérez-López, F. Fabero et F. Chenlo, “Experimental solar spectral irradiance until 2500 nm : results and influence on the pv conversion of different materials”, Progress in photovoltaics : Research and Applications, 15(4), 303-315, 2007.
- [8] P. Krishnan, J. Schuttauf, C. van der Werf, B. Houshyani Hassanzadeh, W. van Sark et R. Schropp, “Response to simulated typical daily outdoor irra-

BIBLIOGRAPHIE

- diation conditions of thin- lm silicon-based triple-band-gap, triple-junction solar cells”, . Solar Energy Materials and Solar Cells, 93(6-7), 691-697, 2009.
- [9] Le corps noir, <https://fermedesetoiles.com/documents/supports/le-corps-noir.pdf>
- [10] Le Rayonnement du corps noir, <https://sciences.brussels/printemps2/pds2002/files/JagerDilawar.pdf>
- [11] Cocquerez J.P. et Philip S., “Analyse d’image : filtrage et segmentation”, ouvrage collectif coordonné par : J.-P. Préface de H. Maître, édition Masson, 1995.
- [12] Philippe Bolon, Jean-Marc Chassery, Jean-Pierre Cocquerez, Didier Demigny, Christine Graffigne, et al., “Analyse d’images : Filtrage et segmentation”, Jean-Pierre Cocquerez ; Sylvie Philipp. MASSON, 1995, Enseignement de la physique, 2-225-84923-4. fhal-00706168.
- [13] Janssen L.L.F., Jaarwa M.N., Yanderlinden E.T.M., “Intergrating topographic data zith sensing for land-cover classification”, Photogrammetric engineering and remote sensing, 56(11), 1503–1506, 1990.
- [14] Turner B.L., Skole D.L., Sanderson S., Fischer G., Fresci L., Leemans L., “Land-use and land-cover change : science / research plan”, International Geosphere-Biosphere Ptogramme, Stockholm ; Repport, 35, 1995.
- [15] Toby N.C., Traci S.A., “The impact of land use-land cover change due to urbanization on surface microclimate and hydrology : a satellite perspective”, Elsevier, Global and Planetary Change, 25(1-2), 49–65, 2000.
- [16] Lambin E.F. et al., “The causes of land-use and land-cover change : moving beyond the myths”, Elsevier, Global Environment Change, 11(4), 261–269, 2001.

BIBLIOGRAPHIE

- [17] Lambin E.F., Geist H.J., Lepers E., “Dynamics of land-use and land-cover change in tropical regions”, *Annual Review of Environment and Ressources*, 28, 205–241, 2003.
- [18] Nagendra N., Munroe D.K., Southworth J., “From pattern to process landscape fragmentation and the analysis of land use /land cover change”, *Elsevier, Agriculture, Ecosystems and Environement*, 101(2-3), 111–115, 2004.
- [19] Trémeau A., Fernandez-Maloigne C. et Bonton P., “Image numérique couleur : de l’acquisition au traitement”, *Dunod, paris*, 2004.
- [20] Macaire L., “Exploitation de la couleur pour la segmentation et l’analyse d’images”, *Thèse de doctorat, université de Lille*, 2004.
- [21] Segmentation, http://bnazarian.free.fr/MyUploads/IN_GBM_05_SEGMENTATION.PDF
- [22] Le seuillage, <https://www.pfl-cepia.inra.fr/index.php?page=tutoImg-seuillage>
- [23] ”Segmentation d’images : principes”, http://glotin.univ-tln.fr/MCBIR/Segmentation_images_principes.pdf
- [24] Segmentation d’image chapitre V, http://bnazarian.free.fr/MyUploads/IN_GBM_05_SEGMENTATION.pdf
- [25] Segmentation d’images : Principes, http://glotin.univ-tln.fr/MCBIR/Segmentation_images_principes.pdf
- [26] H. Oulhadj, A. Nakib et P. Siarry, “Segmentation d’images par maximisation de l’entropie à deux dimensions basée sur le recuit microcanonique”, *Colloque GRETSI*, 773-776, 11-14 septembre 2007, Troyes, 2007.
- [27] Franck Luthon, X. Navarro, M. Liévin. ”Seuillage Entropique En Traitement d’images”. 18e Colloque sur le Traitement du Signal et des Images (GRETSI’01), Toulouse, France. pp.353–356, 2010.

- [28] Bouda B., Masmoudi Lh., et Aboutajdine D., “Cvvefm : Cubical voxels and virtual electric field model for detection in color images”, Signal Processing, Elsevier, 88(4), 905-915, 2008.
- [29] Chabrier S., Emile B., Rosenberger C., Laurent H., “Unsupervised performance evaluation of image segmentation”, Special Issue on Performance Evaluation in Image Processing, EURASIP Journal on Applied Signal Processing, 1-12, 2006.
- [30] Guillaume Cleuziou, “Une méthode de classification non-supervisée pour l'apprentissage de règles et la recherche d'information”, Thèse de doctorat, Université d'Orléans, France, 2004.
- [31] Zennouhi R., Masmoudi Lh. et 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, Tunisia, 2009.
- [32] Lizarazo I., “Urban land cover and land use classification using high spatial resolution images and spatial metrics”, Proceedings of the 2nd workshop of the EARSel SIG on land use and land cover, 2006.
- [33] Ramachandra T.V., Kumar U., “Geographic Resources Decision Support System for land use, land cover dynamics analysis Proceedings of the FOSS / GRASS Users”, Conference, Bangkok, Thailand, 12-14 September 2004.
- [34] Lezoray O., “Unsupervised 2D multiband histogram clustering and region merging for color image segmentation. Dans ISSPIT, pages 267–270, 2003.
- [35] Lezory O., “Segmentation d'image couleur par morphologie mathématique et classification de données par réseaux de neurons : application à la classification de cellules d'objets colors”, Thèse de doctorat, Université de Caen, France, 2000.

- [36] Cheng H.D., Jiang X.H., Sun Y., Wang J., "Color image segmentation : advances and prospects", *Pattern Recognition*, 34(6), 2259-2281, 2001.
- [37] Cheng. H., "A hierarchical approach to color image segmentation using homogeneity", *IEEE Trans on Image Processing*, 9(12), 2071-2082, 2000.
- [38] Maxwell B.A., and Shafer S.A., "Physics-based segmentation : looking beyond color", *Proceedings of Image Understanding Workshop*, 1996.
- [39] Clément A., Vigouroux B., "Unsupervised segmentation of scenes containing vegetation (Forsythia) and soil by hierarchical analysis of bi-dimensional histograms". *Pattern Recognition Letters*, 24, 1951-1957, 2003.
- [40] Clément A., "Algorithmes et outils informatiques pour l'analyse d'images couleur. Application à l'étude de coupes histologiques de baies de raisin en microscopie optique", *Thèse de doctorat*, Université d'Angers, France. 2002.
- [41] Clément A., et Vigouroux B., "Unsupervised classification of pixels in color images by hierarchical analysis of bi-dimensional histograms", *IEEE International Conference on Systems Man and Cybernetics*, Hammamet, Tunisia. vol. 2, p. 85-89, 2002.
- [42] Ortega M., Rui Y., Chakrabarti K., Warshavsky A., Mehrotra S., Huang T.S., "Supporting Ranked Boolean Similarity Queries in MARS", *IEEE Trans. on Knowledge and Data Engineering*, 10(6), 905-925, 1998.
- [43] Vincent L. and Soille P., "Watersheds in digital spaces : An efficient algorithm based on immersion simulation", *IEEE Trans, Pattern Anal*, 13(6), 583-598, 1991.
- [44] Onyango C.M., Marchant J.A., "Physics-based colour image segmentation for scenes containing vegetation and soil", *Image Vision Comput*, 19, 523-538, 2001.
- [45] Lezoray O. and Cardot H., "Hybrid color image segmentation using 2D histogram clustering and region merging", in *ICISP*, 1, 22-29, 2003.

- [46] Xiaojun Q. Ji and Yajun W., “RootLM : a simple color image analysis program for length measurement of primary roots in Arabidopsis”, Plant Root, 1, 10-16, 2007.
- [47] Zennouhi R., Masmoudi Lh., “A new 2D histogram scheme for color image segmentation”, Accepted in The Imaging Science Journal, 2009.
- [48] Sural S., Gang Q., Sakti P., “Segmentation et histogramme génération en utilisant l’espace de couleur **HSV** pour la recherche d’images”, Traitement d’image. Conférence internationale, IEEE, 2, 589-592, 2002.
- [49] Zhang Y.F., Zhang Y., “Another Method of Building 2D Entropy to Realize Automatic Segmentation”, Journal of Physics Conference Series, 48, 303–307, 2006.
- [50] Nixon Mark S. and Aguado Alberto S. ”Feature extraction and image processing”, Computer Science, 2002. <http://www.gbv.de/dms/ilmenau/toc/634710060.PDF>, (DOI <https://doi.org/10.1016/C2009-0-25049-5>).
- [51] Wolfel M. and Ekenel H.K., “Feature Weighted Mahalanobis Distance : Improved Robustness for Gaussian Classifiers”, 13th European Signal Processing Conference, Antalya, Turkey, September 2005.
- [52] Gillet A., Macaire L., Botte-Lecocq C., Postaire J. G., “Color image segmentation by analysis of 3D histogram with fuzzy morphological filters”, in Fuzzy Filters for Image Processing- Studies in Fuzziness and Soft Computing, (M. Nachtegaal, D. Van der Weken, D. Van De Ville and E.E. Kerre), Springer-Verlag Editor, 2002.
- [53] Macaire L., Vandenbroucke N., Postaire J.G., “Color image segmentation by analysis of subset connectedness and color homogeneity properties”, Computer Vision and Image Understanding, 102 (1), 105 – 116, 2006.
- [54] Mechkouri S., Zennouhi R., Masmoudi Lh., Gonzalez J., “Colour Image Segmentation Using Hierarchical Analysis of 2D-Histograms : Application

- to urban land cover and land use classification”, *GEO OBSERVATEUR*, 18, 43-57, 2010.
- [55] 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.
- [56] 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.
- [57] Mechkouri S., El-Joumani S., Zennouhi R., Masmoudi Lh., “Multi-Objective Optimization for Worldview Image Segmentation Funded 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>).
- [58] El-Joumani S., Mechkouri S., Zennouhi R., Masmoudi Lh., “Classification of 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>).
- [59] 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>).
- [60] Borsotti M., Campadelli P., Schettini R., “Quantitative evaluation of color image segmentation results”, *Pattern Recognition Letters*, 19, 741–747, 1998.
- [61] Nakib A., Oulhadj H., Siarry P., “Image histogram thresholding based on multiobjective optimization”, *Signal Processing*, 87, 2516– 2534, 2007.

BIBLIOGRAPHIE

- [62] Pal N.K., Pal S.K., “Entropy : A new definition and its applications”, IEEE Transactions on Systems, Man and Cybernetics, 21, 1260– 1270, 1991.
- [63] Sparavigna AC. “Tsallis entropy in bi-level and multi-level image thresholding”, International Journal of Sciences, 4(1), 40-49, 2015. (ISSN 2305-3925).
- [64] Sparavigna AC “On the role of Tsallis entropy in image processing”, International scientific research journal, IRJ Science 1(6), 16–24, 2015.
- [65] Weszk J.S., Rosenfeld A., “Threshold evaluation techniques”, IEEE Transactions on Systems, Man and Cybernetics, 8(8),622-629, 1978.
- [66] Levine M.D., Nazif A.M., “Dynamic measurement of computer generated image segmentations”, IEEE Transactions on Pattern Analysis and Machine Intelligence, 7(2), 155-164, 1985.
- [67] Sezgin M., Sankur B., “Survey over image thresholding techniques and quantitative performance evaluation”, Journal of Electronic Imaging, 13(1), 146-168, 2004.
- [68] Cochran W.G., “Some methods for strengthening the common $\mathbf{X}^2$ tests”, Biometrics, 10, 417-451, 1954.
- [69] Pal N.R., Pal S.K., “Entropic thresholding”, Signal Processing, 16(2), 97-108, 1989.
- [70] Rosenberger C., “Mise en œuvre d’un système adaptatif de segmentation d’images”, PhD. thèses, Université de Rennes1, Rennes, France, 1999.
- [71] Haralick R.M., Shapiro L.G., ”Image segmentation techniques”, Computer Vision, Graphics, and Image Processing, 29(1), 100–132, 1985.

BIBLIOGRAPHIE

- [72] Coutance V., "La couleur en vision par ordinateur", Thèse de Doctorat de l'Université Paul Sabatier, Toulouse, France, 1991.
- [73] Dartnall H. J. A., Bowmaker J. A. et Mollon J. D., "Human visual pigment : microspectrophotometric results from eyes of seven persons. Proceedings of the Royal Society of London, B 220 :115–130, 1983.
- [74] Gonzalez RC., Woods RE., "Digital Image Processing. Reading", MA : Addison-Wesley. 1993.
- [75] Guo G.D., Yu S. et Ma S.D., "Unsupervised Segmentation of Color Images. IEEE International Conference on Image Processing, pp. 299-302, 1998.
- [76] Kurugollu F., Sankur B., Harmanci A. E., "Color image segmentation using histogram multithresholding and fusion", Image and Vision Computing, vol. 19, pp. 915-928. 2001.
- [77] Leydier Y., Bourgeois F. L. et Emptoz H., "Serialized K-means for adaptive color image segmentation. Application to document images and others", Proceedings of the 6th International Workshop Document Analysis Systems, Florence, Italy, p. 252-263, 2004.

Publications

Articles publiés

[Mechkouri S.](#), Zennouhi R., Masmoudi Lh., Gonzalez J., “Colour Image Segmentation Using Hierarchical Analysis of 2D-Histograms : Application to urban land cover and land use classification”, GEO OBSERVATEUR, 18, 43-57, 2010

[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 Funded 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 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>)

Conférences

Mohammed Amine Azzaoui, Manare Adnani, [Salah Eddine Mechouri](#), Hicham Elbelrhiti, Chaouki Ibrahim ElKhalil, Lhoussaine Masmoudi :“Evaluation of edge detection techniques in HRSI of barchan dunes”. Colloque ATGG-2015, Faculté polydisciplinaire de Taza, Morocco, Taza, Morocco ; 10/2015

Annexes

Annexe 1 : Algorithme de segmentation basée sur l'histogramme 2D

Fonction de Segmentation HSV

Fonction[*imageSeg*, *Q*] = *SegmentaionHSV*(*NoBV*, *NoBH*, *DVH*, *Kh*, *Kv*, *Sh*, *Sv*)

* *I* : image originale

* *NoBV* : nombre de bits pour l'intensité

* *NoBH* : nombre de bits pour hue

* *DVH* : différence entre les valeurs de l'intensité et teinte

* *Kh* et *Kv* : fixe la taille du masque de filtrage dans la d'histogramme qui représente l'intensite et hue respectivement

* *Sh* et *Sv* : seuil de population minimale pour un pic (exprimé en % de la population totale)

C = *rgb2hsv*(*I*)

* transformation de la représentation de l'image de l'espace *RGB* à *HSV*

* Construction de l'histogramme

Hv = *zeros*(256, 256) * initialisation de l'histogramme des intensités

Hh = *zeros*(256, 256)

* initialisation de l'histogramme des teintes

for *i* = 2to*NombreColonne* - 1

For *j* = 2to*NombreLigne* - 1

$th = 1 - 0.8xv(i, j)/255;$

if (*s*(*i*, *j*) < *th*)

$mini = \min([v(i-1, j), v(i, j-1), v(i, j), v(i, j+1), v(i+1, j)])$;

$mini = \text{round}((mini/maxV)*NoBV)+NoBH+DVH;$

$maxi = \max([v(i-1, j-1), v(i-1, j+1), v(i+1, j-1), v(i+1, j+1)])$;

```

     $maxi = round((maxi/maxV) * NoBV) + NoBH + DVH;$ 
     $Hv(mini, maxi) = Hv(mini, maxi) + 1;$ 
  else
     $mini = min([h(i-1, j), h(i, j-1), h(i, j), h(i, j+1), h(i+1, j)]);$ 
     $mini = round((mini/maxH) * NoBH) + 1;$ 
     $maxi = max([h(i-1, j-1), h(i-1, j+1), h(i+1, j-1), h(i+1, j+1)]);$ 
     $maxi = round((maxi/maxH) * NoBH) + 1;$ 
     $Hh(mini, maxi) = Hh(mini, maxi) + 1;$ 
  end
end
end
end
* Segmentation dans l'histogramme dans la zone des pixels représentant
l'intensité
 $H = Hv;$ 
 $[RGB1, PlanRG1] = segmentation(IO, v, s, I, H, DVH, 2, NoBV, NoBH, Sv, K$ 
* Segmentation dans l'histogramme dans la zone des pixels représentant
la teinte
 $H = Hh;$ 
 $[RGB2, PlanRG2] = segmentation2(IO, h, s, v, I, H, 2, NoBH, Sh, Kh);$ 
* Evaluation de la segmentation en utilisant le critère de Borsotti noté  $Q$ 
 $Q = CritereBorsotti(I, ImagSegt)$ 
end

```

Fonction de Segmentation

```

fonction[RGB, PlanRG] = segmentation(IO, v, s, I, H, DVH, P, NoB, NoBH, S,

```

```

    [H, indice, A, N] = hiérarchie2D(I, H, P, S, K) ;
end

```

Fonction *hiérarchie2D*

```

fonction [H, indice, A, N] = hiérarchie2D(I, H, P, S, K) ;
    H = filtregaussien(H, K)
    * lissage de l'histogramme
    J = image77(H)
    * constitution de l'image 8 bits de l'histogramme
    [indice, A, N] = TrouveClasses(I, S, J, A, 1, 1, H, indice)
    * la recherche des classes
end

```

Fonction de Borsotti

```
function  $Q = \text{CritereBorsotti}(I, imSeg)$ 
*  $I$  : l'image original
*  $imSeg$  : image segmenté
*  $R$  : le nombre de régions dans l'image segmentée

 $Iseg1 = imSeg$ ;
 $R = \max(\max(Iseg1))$ 
 $[a, b, c] = \text{size}(I)$ ;
 $N = a * b$ ;
 $Ir = I(:, :, 1)$ ;
 $Ir = \text{double}(Ir)$ ;  $Ir = Ir + 1$ ;
 $Ig = I(:, :, 2)$ ;
 $Ig = \text{double}(Ig)$ ;
 $Ig = Ig + 1$ ;
 $Ib = I(:, :, 3)$ ;
 $Ib = \text{double}(Ib)$ ;
 $Ib = Ib + 1$ ;
 $\max(\max(Iseg1))$ ;
 $\min(\min(Iseg1))$ ;
for  $i = 1 : R$ 
     $Reg = (Iseg1 == i)$ ;
     $[a2, b2, c2] = \text{find}(Reg == 1)$ ;
    * N1 : le nombre de pixels qui constituent la i-ème région
     $N1(i) = \sum(c2)$ ;
end
 $Q1 = 0$ ;
for  $j = 1 : R$ 
     $j$ ;
```

```
Regm = (Iseg1 == j) ;  
[a22, b22, c22] = find(Regm == 1) ;  
Ni =  $\sum$ (c22) ;  
claculedeR(Ni)  
[a3, b3, c3] = find(N1 == Ni) ;  
RN =  $\sum$ (c3) ;  
Ir1 = double(double(Ir). * double(Regm)) ;  
Ig1 = double(double(Ig). * double(Regm)) ;  
Ib1 = double(double(Ib). * double(Regm)) ;  
Ir1 = Ir1(:);  
Ig1 = Ig1(:);  
Ib1 = Ib1(:);   III = Ir1 = 0 ;  
Ir1 = Ir1. * III ;  
[aaa1, bbb1, ccc1] = find(Ir1) ;  
Ir2 = ccc1 ;  
Ir2 = Ir2' ;  
Ig1 = Ig1. * III ;  
[aaa2, bbb2, ccc2] = find(Ig1) ;  
Ig2 = ccc2 ;  
Ig2 = Ig2' ;  
Ib1 = Ib1. * III ;  
[aaa3, bbb3, ccc3] = find(Ib1) ;  
Ib2 = ccc3 ;  
Ib2 = Ib2' ;  
Ir3 = Ir2 - 1 ;  
Ig3 = Ig2 - 1 ;  
Ib3 = Ib2 - 1 ;  
moyenR = mean(Ir3) ;
```

```
moyenG = mean(Ig3) ;  
moyenB = mean(Ib3) ;  
Ir5 = Ir3 - moyenR ;  
Ig5 = Ig3 - moyenG ;  
Ib5 = Ib3 - moyenB ;  
Ir4 = double(Ir5.*Ir5) ;  
Ig4 = double(Ig5.*Ig5) ;  
Ib4 = double(Ib5.*Ib5) ;  
e = Ir4 + Ig4 + Ib4 ;  
e =  $\sqrt{e}$  ;  
ei =  $\sum e$  ;  
Q1 = Q1 + ((ei * ei)/(1 + log(Ni))) + ((RN * RN)/(Ni * Ni)) ;  
end  
Q = (1/(10000 * N)) *  $\sqrt{R}$  * Q1 ;  
end
```

Annexe 2 : Algorithme de segmentation basée sur la Fonction d'onde

Fonction principale

```
close all;
clear all;
clc;
I = imread('TEMARA - RGB321.jpg');
* image-en-niveaux-de-gris
I1 = I;
I = rgb2gray(I);
I2(:, :, 1) = I;
I2(:, :, 2) = I;
I2(:, :, 3) = I;
I = I2;
figure, imshow(I)
break
I1 = I;
R = I(:, :, 1);
G = I(:, :, 2);
B = I(:, :, 3);
[li, co, nn] = size(I)
for j = 1 : 1 : li
    for i = 1 : 1 : co
        maxX = co;
        maxY = li;
        RRY = R(j, i);
        RRY = double(RRY);
```

```

    FonOndR1Y = ( $\sqrt{2/(\max Y)}$ ) * sin((pi * RRY)/maxY);
    FonOndR1(j, i) = FonOndR1Y;
    GGX = G(j, i);
    GGX = double(GGX);
    GGY = G(j, i);
    GGY = double(GGY);
    FonOndR2X = ( $\sqrt{2/(\max X)}$ ) * sin((pi * GGX)/maxX);
    FonOndR2(j, i) = FonOndR2X;
    BBX = B(j, i);
    BBX = double(BBX);
    BBY = B(j, i);
    BBY = double(BBY);
    FonOndR3Y = ( $\sqrt{2/(\max Y)}$ ) * sin((pi * BBY)/maxY);
    FonOndR3(j, i) = FonOndR3Y;
    end
end
FonOndR3 = FonOndR3. * FonOndR3;
FonOndR2 = FonOndR2. * FonOndR2;
FonOndR1 = FonOndR1. * FonOndR1;
[li, c, d] = size(R);
FonOndR1 = reshape(FonOndR1, li, c);
minnnnn = min(FonOndR1(:));
FonOndR1 = FonOndR1 - minnnnn;
maxx = max(max(FonOndR1));
FonOndR1 = round((FonOndR1./maxx). * 255);
FonOndR2 = reshape(FonOndR2, li, c);
minnnnn = min(FonOndR2(:));
FonOndR2 = FonOndR2 - minnnnn;

```

```

maxx = max(max(FonOndR2));
FonOndR2 = round((FonOndR2./maxx). * 255);
FonOndR3 = reshape(FonOndR3,li,c);
minnnnn = min(FonOndR3(:));
FonOndR3 = FonOndR3 - minnnnn;
maxx = max(max(FonOndR3));
FonOndR3 = round((FonOndR3./maxx). * 255);
FonOnd(:,: ,3) = FonOndR3;
FonOnd(:,: ,2) = FonOndR2;
FonOnd(:,: ,1) = FonOndR1;
I = FonOnd;
P = 1;
S = 0.01;
K = 1;
RGB = segmentation(I,P,S,K,I1);
end

```

Fonction de Borsotti

```

function Q = CritereBorsotti(I,imSeg)
* I : l'image original
* imSeg : image segmenté
* R : le nombre de régions dans l'image segmentée
Iseg1 = imSeg;
R = max(max(Iseg1))
[a,b,c] = size(I);
N = a * b;
Ir = I(:,: ,1);
Ir = double(Ir); Ir = Ir + 1;

```

```

Ig = I(:, :, 2);
Ig = double(Ig);
Ig = Ig + 1;
Ib = I(:, :, 3);
Ib = double(Ib);
Ib = Ib + 1;
max(max(Iseg1));
min(min(Iseg1));
for i = 1 : R
    Reg = (Iseg1 == i);
    [a2, b2, c2] = find(Reg == 1);
    * N1 : le nombre de pixels qui constituent la i-ème région
    N1(i) = sum(c2);
end
Q1 = 0;
for j = 1 : R
    j;
    Regm = (Iseg1 == j);
    [a22, b22, c22] = find(Regm == 1);
    Ni = sum(c22);
    claculedeR(Ni)
    [a3, b3, c3] = find(N1 == Ni);
    RN = sum(c3);
    Ir1 = double(double(Ir). * double(Regm));
    Ig1 = double(double(Ig). * double(Regm));
    Ib1 = double(double(Ib). * double(Regm));
    Ir1 = Ir1(:);
    Ig1 = Ig1(:);

```

```
Ib1 = Ib1(:);   III = Ir1 = 0;
Ir1 = Ir1. * III;
[aaa1, bbb1, ccc1] = find(Ir1);
Ir2 = ccc1;
Ir2 = Ir2';
Ig1 = Ig1. * III;
[aaa2, bbb2, ccc2] = find(Ig1);
Ig2 = ccc2;
Ig2 = Ig2';
Ib1 = Ib1. * III;
[aaa3, bbb3, ccc3] = find(Ib1);
Ib2 = ccc3;
Ib2 = Ib2';
Ir3 = Ir2 - 1;
Ig3 = Ig2 - 1;
Ib3 = Ib2 - 1;
moyenR = mean(Ir3);
moyenG = mean(Ig3);
moyenB = mean(Ib3);
Ir5 = Ir3 - moyenR;
Ig5 = Ig3 - moyenG;
Ib5 = Ib3 - moyenB;
Ir4 = double(Ir5. * Ir5);
Ig4 = double(Ig5. * Ig5);
Ib4 = double(Ib5. * Ib5);
e = Ir4 + Ig4 + Ib4;
e =  $\sqrt{e}$ ;
ei =  $\sum(e)$ ;
```

```

     $Q1 = Q1 + ((ei * ei)/(1 + \log(Ni))) + ((RN * RN)/(Ni * Ni));$ 
end
 $Q = (1/(10000 * N)) * \sqrt{R} * Q1;$ 
end

```

Filtre Gaussien

```

function H=filtregaussien(H,K)
     $\sigma = ((2 * k) + 1)/6;$ 
     $h = fspecial('gaussian', [2 * k + 1, 2 * k + 1], \sigma);$ 
     $H = imfilter(H, h);$ 
end

```

Fonction Segmentation

```

function [RGB, PlanRG] = segmentation(I, P, S, K)
    closeall;
    clc;
     $[H, FonOnd, indice, A, N] = hierarchie2D(I, P, S, K);$ 
    indice;
    A;
     $[a, b, c] = size(I);$ 
     $Ir = I(:, :, 1);$ 
    dd = 0;
    indice;
     $PlanRG = zeros(256, 256);$ 
    qs = 0;
    indice2 = indice;
     $Iseg1 = ones(a, b);$ 
    for im = 1 : indice

```

```

     $M = A(im).feuille;$ 
     $qs = qs + 1;$ 
     $M2 = M;$ 
     $M2 = (M2)0;$ 
     $M2 = M2 * qs;$ 
     $PlanRG = PlanRG + M2;$ 
    for  $i = 1 : a$ 
        for  $j = 1 : b$ 
            if ( $M(FonOnd(i, j), FonOnd(i, j)) = 0$ )
                 $Iseg1(i, j) = Iseg1(i, j) + im;$ 
            end
        end
    end
end
end
indice;
 $Iseg1 = Iseg1 - 1;$ 
 $max(max(Iseg1))$ 
 $RGB = Iseg1;$ 
 $PlanRG;$ 
end

```

Fonction Histogramme

```

 $[H, FonOnd] = Histogramme(I, P)$ 
 $PP = P$ 
 $C = rgb2hsv(I);$ 
 $R = C(:, :, 1);$ 
 $R = double(R);$ 
 $G = C(:, :, 2);$ 

```

```
G = double(G);
B = C(:, :, 3);
B = double(B);
[li, c, d] = size(R);
NB = li * c;
maxR = max(max(R));
maxB = max(max(B));
maxG = max(max(G));
[a, b] = size(R);
FonOndR1 = (√2/(maxR)) * sin((pi * R(:))/maxR);
FonOndR2 = (√2/(maxG)) * sin((pi * G(:))/maxG);
FonOndR3 = (√2/(maxB)) * sin((pi * B(:))/maxB);
if(P == 1)
    disp('pre')
    FonOnd = FonOndR1. * FonOndR1;
end
if(P == 2)
    disp('sec')
    FonOnd = FonOndR2. * FonOndR2;
end
if(P == 3)
    disp('troi')
    FonOnd = FonOndR3. * FonOndR3;
end
FonOnd = FonOnd. * FonOnd;
[li, c, d] = size(R);
FonOnd = reshape(FonOnd, li, c);
maxx = max(max(FonOnd));
```

```

FonOnd = round((FonOnd./maxx). * 255);
FonOnd = FonOnd + 1;
H2 = zeros(256, 256);
[a, b, c] = size(I);
size(I);
for i = 1 : 1 : a
    for j = 1 : 1 : b
        H2(FonOnd(i, j), FonOnd(i, j)) = H2(FonOnd(i, j), FonOnd(i, j)) +
1;
    end
end
H = H2;
end

```

Fonction Trouver les Classes

```

function [indice, A, N] = TrouveClasses(S, I, J, A, N0, N, H, indice)
A(N0).noeud;
J;
I;
[NbPics, Masques] = ComposantesConnexes(I, J, S, A, N0, H);
Masques;
A(N0).noeud;
NbPics;
if (NbPics > 1)
    A;
    E = zeros(256, 256);
    L = A(N0).noeud;
    for w = 1 : NbPics

```

```
Q = Masques(w).pics ;
E2 = L&Q;
E = E + E2 ;
end
E = E.*A(N0).noeud ;
E = A(N0).noeud − E ;
[m,n] = size(find(E)) ;
if(n == 0)
    for i = 1 : NbPics
        Masques ;
        A = remplirNoeud(A,i,N,Masques) ;
    end
else
    NbPics ;
    for i = 1 : NbPics
        Masques ;
        Masque = Masques(i).pics ;
        [Dist1] = MesureDistance(E,Masque) ;
        Dist(i,:) = Dist1 ;
    end
    Dist ;
    IndicePic = QuelPic(Dist) ;
    for i = NbPics : −1 : 1
        A = remplirNoeud2(A,i,N,Masques,IndicePic,E,I) ;
    end
end
ancienN = N ;
ancienJ = J ;
```

```

     $N = \text{ancien}N + \text{NbPics};$ 
    for  $i = 1 : \text{NbPics}$ 
         $J = \text{ancien}J;$ 
         $J = \text{Masques}(i).\text{pics};$ 
         $[\text{indice}, A, N] = \text{TrouveClasses}(S, I, J, A, \text{ancien}N +$ 
 $i, N, H, \text{indice});$ 
    end
else
     $abc = A(N0).\text{noeud};$ 
     $\text{indice} = \text{indice} + 1;$ 
     $A(\text{indice}).\text{feuille} = abc;$ 
end
end
end

```

Fonction Mesure de Distance

```

function[Dist1] = MesureDistance(E, Masque);
    Dx1 = 0 : 255;
    Dx2 =  $\sum(\text{Masque});$ 
    Dx3 = Dx1.* Dx2;
    Dx3 =  $\sum(\text{Dx3});$ 
    Xi = Dx3/  $\sum(\text{Dx2});$ 
    cx = Xi;
    Masquey = Masque';
    Dy2 =  $\sum(\text{Masquey});$ 
    Dy2 = Dy2';
    Dy1 = Dx1';
    Dy3 = Dy1.* Dy2;
    Dy3 =  $\sum(\text{Dy3});$ 

```

```
 $Xj = Dy3/sum(Dy2);$   
 $cy = Xj;$   
 $[L, C] = size(Masque);$   
 $S = 0;$   
for  $i = 1 : L$   
    for  $j = 1 : C$   
        if ( $Masque(i, j) \gg 0$ )  
             $S1 = Masque(i, j) * (i - cy) * (j - cx);$   
             $S = S + S1;$   
        end  
    end  
end  
 $v12 = S / \sum(\sum(Masque));$   
 $S = 0;$   
 $[L, C] = size(Masque);$   
for  $i = 1 : L$   
    for  $j = 1 : C$   
        if ( $Masque(i, j) \gg 0$ )  
             $S1 = Masque(i, j) * (j - cx) * (i - cy);$   
             $S = S + S1;$   
        end  
    end  
end  
 $v21 = S / \sum(\sum(Masque));$   
 $S = 0;$   
 $[L, C] = size(Masque);$   
    for  $i = 1 : L$   
        for  $j = 1 : C$ 
```

```

        if(Masque(i, j) > 0)
            S1 = Masque(i, j) * (j - cx) * (j - cx);
            S = S + S1;
        end
    end
end
v11 = S /  $\sum(\sum(\textit{Masque}))$ ;
S = 0;
[L, C] = size(Masque);
    for i = 1 : L
        for j = 1 : C
            if(Masque(i, j) > 0)
                S1 = Masque(i, j) * (i - cy) * (i - cy);
                S = S + S1;
            end
        end
    end
v22 = S /  $\sum(\sum(\textit{Masque}))$ ;
M = double([v11v12; v21v22]);
M = inv(M);
[L2, C2] = size(E);
[L, C] = size(find(E));
P = ones(L, 2);
k = 1;
    for h = 1 : L2
        for l = 1 : C2
            if(E(h, l) > 0)
                P(k, :) = [(l - cx)(h - cy)];
            end
        end
    end

```

```
         $k = k + 1;$   
    end  
end  
end  
 $P = \text{double}(P);$   
 $[ll, cc] = \text{size}(P);$   
 $d = [];$   
for  $i = 1 : ll$   
     $P2 = P(i, :);$   
     $d2 = \text{double}(P2 * M * P2');$   
     $d = [d; d2];$   
end  
 $Dist1 = d;$   
end
```

Annexe 3 : Algorithme de segmentation basée sur la Fonction multiobjectif

Fonction_principale

```
close all ;  
clear all ;  
clc ;  
I = imread('imagestest.png') ;  
III = I ;  
imhist(I)  
I = I + 1 ;  
H2 = zeros(256, 256) ;  
[a, b] = size(I) ;  
for i = 2 : 1 : a - 1  
    for j = 2 : 1 : b - 1  
        moy = I(i, j) ;  
        H2(I(i, j), moy) = H2(I(i, j), moy) + 1 ;  
    end  
end  
H = H2 ;  
[TabCentGravf] = segmentationSeg(I, H, 2, 3, 0.5, III) ;
```

```
function [TabCentGravfRGBNn] = segmentationSeg(I, H, P, S, K, III)
```

```
[H, , A, N, TabCentGravf] = hierarchie2D(I, H, P, S, K) ;  
h = imhist(I) ;  
hh =  $\sum(h(1 : 256))$  ;  
VCG = sort(unique(floor(TabCentGravf)))
```



```

 $\Sigma(n) = 0;$ 
for  $j = (\text{position2}(n) + 1) : \text{position2}(n + 1)$ 
     $\Sigma(n) = \Sigma(n) + (\sum(h(j))/hh) * (j - Mu(n))^2;$ 
end
 $En(n) = 0;$ 
for  $j = (\text{position2}(n) + 1) : \text{position2}(n + 1)$ 
     $En(n) = En(n) + (((h(j)/hh)/Pt(n)) * \exp(1 -$ 
 $((h(j)/hh)/Pt(n)))));$ 
end
 $En1(n) = 0;$ 
for  $j = (\text{position2}(n) + 1) : \text{position2}(n + 1)$ 
     $En1(n) = En1(n) + ((h(j)/hh)/Pt(n))^{AA};$ 
end
 $Ents1(n) = (1 - En1(n))/(AA - 1);$ 
 $Rn(n) = 0;$ 
for  $j = (\text{position2}(n) + 1) : \text{position2}(n + 1)$ 
     $Rn(n) = Rn(n) + (h(j)/hh)^{AAA};$ 
end
 $R(n) = (1/(1 - AAA)) * \log(Rn(n));$ 
 $Mm(n) = 0;$ 
for  $j = (\text{position2}(n) + 1) : \text{position2}(n + 1)$ 
     $Mm(n) = Mm(n) + (h(j)/hh) * j^{AA};$ 
end
 $Exp(n) = 0;$ 
for  $j = (\text{position2}(n) + 1) : \text{position2}(n + 1)$ 
     $Exp(n) = Exp(n) + ((h(j)/hh)/Pt(n))^{AAA};$ 
end
 $Exp = (Exp)^{1/(1 - AAA)};$ 

```

```
end
Mut = 0;
Mutt = 0;
for s = 1 : length(VCG)
    Mut = Mut + Pt(s) * Mu(s);
    Mutt = Mutt + Mu(s);
end
* calcule la variance interclasse
SigmaInter = 0;
for i = 1 : length(VCG)
    SigmaInter = SigmaInter + Pt(i) * (Mu(i) - Mut)2;
end
SigmaInter =  $\sqrt{\text{SigmaInter}}$ ;
Alpha =  $\sqrt{\text{length}(\text{VCG})} / (10000 * \text{size}(\text{I}, 1) * \text{size}(\text{I}, 2))$ ;
* calcule le critère de variance intra-classe biaisée
Mvar = 0;
a2 = 0;
PE = 0;
Ent = 0;
Ets1 = 0;
Ets2 = 1;
RN = 0;
Mmt = 0;
Eexpo = 0;
for l = 1 : length(VCG)
    Mvar = Mvar + ((1 + log(N(l)) + (1/(N(l))2)));
    a2 = a2 +  $\Sigma(l)$ ;
    PE = PE + Pt(l)2;
```

```

    Ent = Ent + En(l) ;
    RN = RN + R(l) ;
    Mmt = Mmt + Mm(l) ;
end
Mvar = Alpha * SigmaInter2*Mvar ;
a2 = a2/SigmaInter2 ;
a3 = Mut/Mutt ;
a33 = 1/2 * AA + AAA ;
a1 = 1 - a2 - a3 ;
a11 = 1 - a2 - a33 ;
* calcule le critère de la probabilité de l'erreur de classification
A = 0 ;
if(length(Ents1) <= 2)
    ET =  $\sum$ (Ents1) + (1 - AA) * prod(Ents1) ;
else
    for i = 0 : length(Ents1) - 3
        for j = 1 : length(Ents1) - 1 - i
            for l = j + 1 : length(Ents1) - i
                A = A + (1/2 * (i + 1)) * (1 - AA)(i + 1) * prod(Ents1(j :
j + i)) * Ents1(l + i) ;
            end
        end
    end
    ET =  $\sum$ (Ents1) + A + ((1 - AA)(length(Ents1) - 1)) *
prod(Ents1) ;
end
* la fonction objectif équivalente
MOBJ1 = a1 * Mvar + a2 * PE + a3 * Ent ;

```

```
MOBJ = a1 * ET + a2 * RN ;
if MOBJ > MinObj
  MinObj = MOBJ ;
  MinT = T ;
end
if MOBJ1 < MinObj1
  MinObj1 = MOBJ1 ;
  MinTT = T ;
end
VS(q) = MinT ;
VS1(q) = MinTT ;
end
end
VS
VS1
segI = imquantize(I, VS) ;
segtI = imquantize(I, VS1) ;
RGB = label2rgb(segI) ;
RGBt = label2rgb(segtI) ;
RGBN = rgb2gray(RGB) ;
RGBNt = rgb2gray(RGBt) ;
Imseg = segI ;
Imdep = I ;
Imori = I ;
CRiintermul = InterLN(Imdep, Imseg)
Imseg = segtI ;
CRiintermulan = InterLN(Imdep, Imseg)
Imseg = segI ;
```

```
CRintramul = IntraLN(Imdep, Imseg)
Imseg = segI;
CRintramulan = IntraLN(Imdep, Imseg)
Imseg = segI;
CRintraintermul = IntraInterLN(Imseg, Imori)
Imseg = segI;
CRintraintermulan = IntraInterLN(Imseg, Imori)
I = double(I);
Imseg = segI;
ERRmul = immse(I, Imseg)
Iseg1 = segI;
Cmul = CriteLevineNazif(Iseg1, I)
ERRmulan = immse(I, Imseg)
Iseg1 = segI;
Cmulan = CriteLevineNazif(Iseg1, I)
subplot(1, 3, 1), imshow(III), title('Image''ImagSat4''');
subplot(1, 3, 2), imshow(RGBNt), title('Multi
Objective1method');
subplot(1, 3, 3), imshow(RGBN), title('Multi
Objective2method');
end
```
