

REPUBLIQUE ALGERIENNE DEMOCRATIQUE ET POPULAIRE
MINISTERE DE L'ENSEIGNEMENT SUPERIEUR ET DE LA RECHERCHE SCIENTIFIQUE
UNIVERSITE MOHAMED BOUDIAF - M'SILA

FACULTE DE TECHNOLOGIE
DEPARTEMENT D'ELECTRONIQUE

N° :



DOMAINE : SCIENCE & TECHNOLOGIE
FILIERE : ELECTRONIQUE
OPTION : ELECTRONIQUE DES SYSTEMES
EMBARQUES

Mémoire présenté pour l'obtention
Du diplôme de Master Académique
Par : FAID SARRA & DEHIMI Wafa

Intitulé

Modèle de segmentation d'image à
champ aléatoire de markov (MRF)

Soutenu devant le jury composé de :

Dr KHALFA ALI	Université Mohamed boudiaf – M'sila	Président
Dr LALAOUI .L	Université Mohamed boudiaf – M'sila	Rapporteur
Dr ZERDOUMI Zohra	Université Mohamed boudiaf – M'sila	Examineur

Année universitaire : 2019 /2020

بِسْمِ اللَّهِ الرَّحْمَنِ الرَّحِيمِ



DEDICACE

Nous dédions ce travail à :

*Nos mères, sources de tendresse et d'amours pour leurs
soutiens tout le long de notre vie scolaire.*

*Nos pères, qui nous ont toujours soutenus et qui ont fait
tout possible pour nous aider.*

Nos frères et nos sœurs, que nous aimons beaucoup.

Notre grande famille.

Nos cher ami (e)s, et enseignants.

*Tout qu'ont collaboré de près ou de loin à l'élaboration de ce
travail.*

REMERCIEMENTS

Nous tenons à remercier tout premièrement Allah le tout puissant pour sa volonté, sa santé et sa patience, qu'il nous a donné durant toutes ces longues années.

Ainsi, nous tenons également à exprimer nos vifs remerciements à mon encadreur Monsieur Lahouacui Lalaoui pour avoir d'abord proposé ce thème, pour leur suivi continuel tout au long de la réalisation de ce mémoire et qui n'ont pas cessé de nous donner leurs conseils.

Nos remerciements vont aussi à tous les enseignants et le chef de département Electronique qui a contribué à notre formation.

Nos sincères remerciements à tous les membres de jury qui nous ont fait l'honneur en acceptant d'examiner ce travail.

Enfin, un remerciement spécial à mes amis pour le soutien moral.

Resume

La segmentation d'image (détection des lignes de texture) est un problème clé dans le traitement d'image. Parmi les différents modèles et approches qui ont été développés, certains sont Les techniques statistiques couramment utilisées sont basées sur le modèle de champ de Markov et nous présentons la Combinaison de l'utilisation des algorithmes KMeans, EM (VacheVsVtion des attentes) base sur de critères d'évaluation (MSE , PSNR , NCC, NAE, MD , SC) pour obtenir une image de bonne qualité avec des contours et régions claires

Mots Clés : Segmentation d'image, champ aléatoire de markov, markov caché

Abstact

Image segmentation (detection of texture lines) is a key problem in image proressing. Among the different models and approaches that have been developed, same are the most widely used statistical technique are based on the Markov field model. We present the combination of the use Kmeans EM (expectation maximization) algorithms based on evaluation criteria (*MSE, PSNR, NCC, NAE, MD, SC*) for a good quality image with clear aoutlines and regions

Keywords: *Image segmentation, random markov field, hidden markov*

Sommaire

LISTE DES FIGURES

LISTE DES TABLEAUX

NOTAIONS ET ABREVIATIONS

Introduction
générale

1

Chapitre I :Généralites sur le traitement d'image

I.1 Introduction.....	3
I.2 Le traitement d'image.....	3
I.2.1 Historique	3
I.2.2 Définition.....	4
I.3 Numérisation de l'image.....	4
I.3.1 Définition d'une image	4
I.3 .2 Définition de l'image numérique.....	4
I.3 .3 Echantillonnage et quantification de l'image	5
I.4 Codification d'une image numérique	7
I.4.1 Images binaires (en noir et blanc).....	7
I.4.2 Images à niveaux de gris (Monochromes).....	7
I.4.3 Images en couleurs (Polychromes).....	8
I.5 Les caractéristiques d'une image numérique.....	9
I.5.1. Pixel.....	9
I.5.2La résolution	9
I.5.3Dimension:.....	Erreur ! Signet non défini.
I.5.4 La texture	10
I.5.5 La luminance.....	10
I.5.6 Le contours	10
I.5.7 Regions	11
I.5.8 Histogramme d'une image.....	11
I.5.9 Contraste	12
I.5.10 Le bruit.....	13

I.6 Système de traitement d'image	13
I.6.1 Acquisition et numérisation:	14
I.6.2 Visualisation	14
I.7 traitement numérique des images	14
I.7.1 Filtrage Numérique	14
I.7.2 Domaines d'application	17
I.8 Conclusion	17

Chapitre II: Les approches de la segmentation d'images :

II.1 Introduction	18
II.2 Définition de la segmentation.....	18
II.3 Définition formelle de la segmentation	19
II.4 Objectifs de la segmentation	19
II.5 Les étapes de segmentation d'images.....	20
II.6 Segmentation d'images 2D, et au-delà.....	20
II.6.1 La segmentation 2D.....	20
II.6.2 La segmentation 3D.....	21
II.7 Différentes approches de segmentation	22
II.8 Approches Contours	22
II.8.1 Méthodes dérivatives	23
II.8.2 Méthodes analytiques	25
II.8.3 Méthodes déformables.....	26
II.8.4 La limite de segmentation par contour	27
II.9 Approche région	27
II.9.1 Croissance de région (région growing):	27
II.9.2 Segmentation par fusion de régions (Merge)	28
II.9.3 Segmentation par division de régions (Split)	28
II.9.4 Segmentation par division-fusion (Split and Merge)	29
II.10 Segmentation par seuillage.....	30
II.10.1 Définition du seuillage	30
II.11 Généralités sur la segmentation des images médicales :	32
II.12 Conclusion.....	33

Chapitre III :Segmentation par champ aléatoire deMarkov (MRF)

III.1 Introduction:.....	35
--------------------------	----

III.1.1 Historique :.....	35
III. 1 Modèles de Markov cachés :.....	36
III. 1.2. Définitions des éléments d'un modèle MMC :	36
III.1.3 Formalisme :.....	36
III.1.4 Les champs de Markov cachés:.....	37
III.1.5 Modèle Markovien Cachée pour la segmentation d'images :	40
III.1. 6 Les Chaines de Markov cachés	41
III.2 Modélisation probabiliste de l'image	41
III.3 Champs de Markov et champs de Gibbs.....	42
III.3.1 Les Champs aléatoires de Markov en Analyse d'Images.....	42
III.3.2 principe de la segmentation markovienne	43
III.4 Quelques MRF fondamentaux	44
III.4.1 Le modèle d'Ising	44
III.4.2 Le modèle de Potts	45
III.7.3 Modèle Markovien Gaussien	46
III.4.3Echantillonnage de MRF.....	47
III.5 AlgorithmeK-means.....	47
III.5.1 Définition :	47
III.5.2 Algorithme KMeans:.....	48
III.6 Algorithme ICM (IteratedConditionnal Modes) :	49
III.7 Algorithme EM :	49
III.8Avantages du MRF	50
III.9 Conclusion	50

Chapitre IV :Simulations et interprétation des Résultats

IV.1 Introduction.....	52
IV.2 Rappels sous Matlab :	52
IV.2.1 Lire et écrire des images sous Matlab :.....	52
IV.3 Mesure de la qualité :	53
IV.4 Evaluation objective :	53
IV.4 .1 Les méthodes avec référence complète,.....	53
IV.4 .2 Les méthodes sans référence,.....	53
IV.4 .3 Méthodes avec référence réduites,	54

IV.5 MÉTRIQUES DE QUALITÉ D'IMAGE	54
IV.5.1 Erreur quadratique moyenne (MSE)	54
IV.5.2 Le rapport signal sur bruit crête (PSNR)	55
IV.5.3 Contenu structurel :	55
IV.5.4 Corrélacion croisée normalisée :	55
IV.5.5 Différence maximale :	55
IV.5.6 Erreur absolue normalisée :	56
IV.6 Résultats de simulation	56
IV.6.1 Segmentation des images synthétiques:	56
IV.7 Segmentation des images réelles :	57
IV.7.1 Segmentation d'image N01	57
IV.7.2 Segmentation d'image N02 :	58
IV.8 Conclusion	59
Conclusion générale	61
Bibliographie	63

Liste des figures

CHAPITRE I

Figure I.1: Représentation d'image numérique.	5
Figure I.2 : quantification d'une image.....	6
Figure I.3 : Exemple d'image utilisant une quantification de 1 bit/composante primaire	6
Figure I.4 : Image binaire	7
Figure I.5 : Image Monochrome (256 couleurs).....	8
Figure I.6 : Image polychrome (65536 couleurs)	8
Figure I.7 : groupe de pixel formant la lettre A.	9
Figure I.8 : Contour d'une image.	10
Figure I.9 : Histogramme d'une image en niveaux de gris.....	11
Figure I.10 : Egalisation d'un histogramme en niveaux de gris	12
Figure I.11 : Images avec contraste différent	12
Figure I.12 : Image sans bruit	13
Figure I.13 : Image avec bruit.....	13
Figure I.14 : Composition d'un système de traitement numérique.	13
Figure I.15 : Principe du filtre médian.	17
Figure I.16 : Principe du filtre maximum.	16
Figure I.17 : Principe du filtre minimum.	18

CHAPITRE II

Figure II.1 : Exemple de segmentation d'image.....	19
Figure II.2 : Etapes de segmentation d'images.....	21
Figure II.3 : IRM patient 1 (a) , Segmentation patient 1 (b)	21
Figure II.4 : Segmentations parallèle des images 3D.	22
Figure II.5 : quelques modèles de contours.	22
Figure II.6 : Contour et ses dérivées.	23
Figure II.7 : Détection de contour par les différents filtres.	25
Figure II.8 : Image originale (à gauche), contour détecté par le Laplacien.	25
Figure II.9 : croissance progressive des regions.....	28

Figure II.10 : Décompositions successives des blocs.....	30
Figure II.11 Agrégation itérative des blocs similaires au bloc	30
Figure II.12 Seuillage simple d'un histogramme.	31
Figure II.13 Seuillage multiple d'un histogramme.....	31
Figure II.14 Principales méthodes de segmentation des images médicale.....	32
Figure II.15:La décomposition en 4 peut faire apparaître des blocs similaires.....	29
Figure II.16 Les décompositions successives peuvent faire apparaître des bloc similaires.....	29

CHAPITRE III

Figure III.1 : Figure III.1 exemple d'automate probabiliste d'états finis (composé ici de 3 états).....	36
Figure III.2 : Figure III.2 Détaille de probabilité de transition et d'émission d'une donnée dans le modèle de Markov caché	37
Figure III.3 : <i>Voisinage de pixel et clique de 4 connections</i>	38
Figure III.4 : <i>Parcours d'Hilbert-Peano</i>	36
Figure III.5 : modèle d'Ising, MRF à 2-D.....	45
Figure III.6 : Exemple modèle de Potts avec différentes valeurs de β	46
Figure III.7 : Exemple modèle de Potts généralisé.. ..	46

CHAPITRE IV

Figure IV.1 :Figure IV.1 a) Image original, b) Segmentation par MRF base K-Means, c) segmentation par MRF basée EM	56
Figure IV.2 : a) Image original, b) Segmentation par MRF base K-Means, c) MRF base EM.....	57
Figure IV.3 : a) Image original, Segmentation par b) MRF base K-Means, c) MRF base EM.....	58

Liste des tableaux

CHAPITRE IV

Tableau IV.1: Valeurs des critères d'évaluation des résultats de segmentation.....	57
Tableau IV.2 : Valeurs de 6 critères d'évaluation des résultats de segmentation 1.....	58
Tableau IV.3 : Valeurs de 6 critères d'évaluation des résultats de segmentation 2.....	59

Liste des symboles

Notations et symbols

	Déterminant
α	Paramètre d'interaction
λ	Paramètre de régularité.
β	Paramètre associé aux singletons
Θ	Vecteur Paramètre
B	Champ magnétique externe
C	Ensemble de cliques
c	Clique
Cr	Crédibilité
∇	Gradient
δ	Symbole de Kronecker.
E	Espace de valeurs des descripteurs.
exp, e	Exponentiel
γ	Fonction de partition
Ω	Ensemble de classes
ω_i	Classe
φ	Fonction potentielle
$I(i, j)$	Intensité du pixel de coordonnées (i, j) de l'image I .
L	Vraisemblance
max	Maximum.
P	Rapport à la probabilité
$P(\Omega)$	Ensemble des parties de Ω
R	Ensemble des réels
S	Ensemble des pixels
s	Site ou pixel
T	Seuil global fixe
U	Fonction énergie

U_s	<i>Energie locale en un site s</i>
V_s	<i>Système de voisinage</i>
V	<i>Ensemble de voisins de s</i>
X	<i>Champ aléatoire de Markov</i>
X_s, Y_s	<i>Variable aléatoire</i>
Y	<i>Champ observé</i>
Z_s	<i>Facteur de normalisation</i>
NG	<i>Niveau de gris.</i>
Pixel	<i>Picture element.</i>
RVB	<i>Rouge / Vert / Bleu.</i>
CG	<i>Champ de Gibbs</i>
CM	<i>Champ de Markov</i>
CMC	<i>Champ de Markov Caché</i>
CMCouple	<i>Champ de Markov Couple</i>
ICM	<i>Mode Conditionnel Itéré (IteratedConditionnal Modes).</i>
EM	<i>Expectation Maximisation</i>
BMP	<i>Bit Map Picture.</i>
JPEG	<i>Joint Photographic Experts Group.</i>
Tiff	<i>Tagged Image File Format.</i>
PNG	<i>Portable Network Graphics.</i>
PS/EPS	<i>Postscript / Encapsulated Postscript.</i>
IRM	<i>Image par résonance magnétique.</i>
MSE	<i>Erreur quadratique moyenne (Meansquarederror)</i>
PSNR	<i>Rapport crête signal sur bruit (Peak Signal to Noise Ratio).</i>
SC	<i>Contenu structurel (Structural Content).</i>
NCC	<i>Corrélation croisée normalisée (Normalized Cross Correlation).</i>
MD	<i>Différence maximale (Maximum difference).</i>
NAE	<i>Erreur absolue normalisée (Normalizedabsoluteerror)</i>

Introduction générale

La segmentation d'image est un problème important dans le domaine de l'analyse d'image. Elle est fortement utilisée en imagerie médicale afin d'analyser et de quantifier les différentes structures anatomiques présentes dans les images. Les méthodes de segmentation peuvent être classées selon le but à atteindre. Il existe des méthodes qui déterminent des régions dans l'image et d'autres qui cherchent à déterminer les frontières de ces derniers.

La segmentation d'image est l'opération la plus importante dans un système de traitement d'images, car elle est située à l'articulation entre le traitement et l'analyse des images. L'intérêt de la segmentation est de partitionner une image en plusieurs régions homogènes, au sens d'un critère fixé a priori. L'intérêt de disposer de régions homogènes est de fournir des données simplifiées qui facilitent la tâche d'un système de reconnaissance de formes, ou autre système d'extraction des objets contenus dans l'image.

Les techniques de segmentation d'image sont généralement fondées sur la recherche des discontinuités locales (détection de contours) ou la détection de zones de l'image présentant des caractéristiques d'homogénéité (extraction de régions). Les approches de segmentation par région, quant à elles, agissent en partitionnant l'image en un ensemble de régions. Chaque région va définir un ou plusieurs objets connexes. Cependant, ces approches ont tendance à déformer les frontières naturelles des objets. Les meilleurs résultats de segmentation sont obtenus en faisant coopérer des méthodes distinctes. Ce sont des approches plus efficaces, car les inconvénients d'une méthode peuvent être surpassés par les avantages d'une autre méthode.

Le but de ce projet est de combiner l'utilisation des k-means et EM (Expectation Maximisation) dans les champs de Markov pour segmenter en régions distinctes d'une image. La classification par k-means nous permet d'obtenir des régions compactes dans l'espace RGB des couleurs, cependant les zones obtenues sont fragmentées au niveau de l'image. Cela est dû au fait qu'aucune information spatiale n'a été prise en compte lors de la classification par k-means. Le formalisme des champs de Markov nous permet d'obtenir des classifications plus régulières en favorisant une régularité entre les pixels voisins. Ce

pendant l'utilisation de ce modèle impose un certain nombre de choix : choix du système de voisinage pour les cliques, choix du potentiels associé aux cliques, choix de l'estimateur et de la méthode d'optimisation. Nous allons présenter et comparer les résultats obtenus en fonction des différents choix possibles.

Ce mémoire s'articule autour de quatre chapitres qui nous permettront de présenter les différents aspects de notre travail. Le premier présente des généralités sur le traitement d'image. Nous avons ensuite présentés dans le chapitre deux les méthodes de segmentation d'images, où nous avons décrit un certain nombre de méthodes classiques de segmentation, soit par approche contour ou par région. Le troisième on a présenté la modélisation du problème de la segmentation par les MRFs, et leurs différents modèles. Le quatrième chapitre est la partie expérimentations et résultats obtenus où nous montrons l'apport de la coopération de la segmentation par Segmentation par l'algorithme K-Means et Segmentation par l'algorithme EM. Nous terminons ce travail par une conclusion générale et perspective.

Chapitre I

Généralités sur le traitement d'image

I.1 Introduction

Le traitement d'image peut être défini comme l'ensemble des méthodes et techniques opérant sur l'image afin d'extraire les informations les plus pertinentes ou tout simplement pour fournir une image plus perceptible à l'oeil humain.

Dans ce chapitre nous présentons quelques notions de base du domaine de traitement d'image numérique tels que : la définition d'image, numérisation de l'image, échantillonnage et quantification de l'image, caractéristiques d'image, système de traitement d'image et filtrage.

I.2 Le traitement d'image

I.2.1 Historique

Le traitement d'images voit ses débuts dans les années 1920 dans la transmission des données par le câble sous-marin allant de New York à Londres, mais ne connaît de vraies avancées que dans les années 1960 avec le développement des ordinateurs. Au départ, les techniques de traitement d'images sont fondées sur des méthodes de restauration et de compression d'images. Puis se développent de nouvelles de détection de primitives (contours, point d'intérêt, lignes d'intérêt ...) et de nombreux autres traitements telles que l'extraction d'attributs et la reconnaissance des formes. En fait ces traitements ont deux objectifs : -Améliorer la qualité de l'image et la rendre "lisible" sans défauts et d'en extraire des informations jugées pertinentes. - Préparer à l'analyse : Segmentation en vue de modifier son contenu (élimination du bruit ou renforcement des contours par exemple) : Dans ce cas sont appliquées les fonctions communes (filtrage, contours, contraste, clarté,...). Dans le domaine du traitement d'images, On trouve différents outils dédiés à des sous-domaines aussi variés : imagerie biomédicale, analyse d'objets, imagerie satellitaire, traitement de documents. [1]

I.2.2 Définition

Le traitement d'image est une opération qui commence avec une image et finit avec une autre ou bien une image corrigée. Cette opération ne doit être confondue avec l'analyse d'image qui débute sur une image et en extrait des résultats brefs, réduisant les données nécessaires pour stocker l'image originale comme un tableau des pixels. Le traitement produit habituellement une autre image aussi grande que l'originale mais dans laquelle les valeurs des pixels (intensité ou couleur) ont changé. [2]

I.3 Numérisation de l'image

I.3.1 Définition d'une image

L'image est une Représentation d'un objet par les arts graphiques ou plastiques la sculpture, la photographie, le dessin, le film, etc. [28]. C'est aussi un ensemble structuré d'informations qui, après affichage sur l'écran, ont une signification pour l'œil humain.

Elle peut être décrite sous la forme d'une fonction $F(x, y)$ de brillance analogique continue, définie dans un domaine borné, tel que x et y sont les coordonnées spatiales d'un point de l'image et F est une fonction d'intensité lumineuse et de couleur. Sous cet aspect, l'image est inexploitable par la machine, ce qui nécessite sa numérisation [29].

I.3.2 Définition de l'image numérique

L'image numérique est l'image dont la surface est divisée en éléments de taille fixe appelés cellules ou pixels, ayant chacun comme caractéristique un niveau de gris ou de couleurs. [2]

La numérisation d'une image est la conversion de celle-ci de son état analogique en une image numérique représentée par une matrice bidimensionnelle de valeurs numériques $f(x, y)$, comme la montre la figure où :

x, y : coordonnées cartésiennes d'un point de l'image.

$f(x, y)$: niveau d'intensité.

La valeur en chaque point exprime la mesure d'intensité lumineuse perçue par le capteur. [3]




Figure I.1 Représentation d'image numérique.

I.3 .3 Echantillonnage et quantification de l'image

La quantification détermine la qualité de l'échantillonnage du signal. Celui-ci se mesure en nombre de bits par pixel de l'image (bpp). La précision du rendu colorimétrique de l'image dépend du nombre de niveaux du signal pouvant être codés pour chaque pixel. Les valeurs les plus courantes sont 8 bits/pixel pour les images en niveaux de gris (256 niveaux de gris) et 24 bits/pixels, c'est à dire 8 bits par composantes primaires, pour les images en couleur (plus de 16 millions de couleurs distinctes). Les images suivantes illustrent l'influence de la quantification (nombre de bits pour le codage de chaque composante primaire) sur la qualité de l'image. Par rapport à l'image originale codée sur 8 bits par composante, la dégradation est progressive jusqu'à atteindre une image qui est "monochrome" dans chacune des couleurs primaires (image retravaillée en contraste).

Couleurs restituées sur le plan de la perception visuelle. Cela se réalise en mettant à profit la densité d'information spatiale (résolution de l'image) et les limites de l'acuité visuelle pour créer artificiellement de nouvelles couleurs perçues, mais au détriment de la résolution résultante et de la qualité intrinsèque du signal contenu dans l'image.



Figure I.2 quantification d'une image

Certaines techniques de tramage permettent d'augmenter artificiellement le nombre de couleurs. Il est possible d'utiliser, par exemple, un tramage de diffusion (régulier ou aléatoire) permettant de répartir les erreurs colorimétriques par rapport à l'image modèle sur des pixels adjacents. [4]



Figure I.3 Exemple d'image utilisant une quantification de 1 bit/composante primaire

I.4 Codification d'une image numérique

I.4.1 Images binaires (en noir et blanc)

Une image binaire est une image $M \times N$ où chaque point peut prendre uniquement la valeur 0 ou 1. Les pixels sont noirs (0) ou Blancs (1). Le niveau de Gris est codé sur un bit (BinarydigIT). Dans ce cas avec $N_g = 2$ et la relation sur les niveaux de gris devient : $p(i, j) = 0$ ou $p(i, j) = 1$. [34]



Figure I.4 Image binaire

I.4.2 Images à niveaux de gris (Monochromes)

Le niveau de Gris est la valeur de l'intensité lumineuse en un point. La couleur du pixel peut prendre des valeurs allant du noir au Blanc en passant par un nombre fini de niveaux intermédiaires. Donc pour représenter les images à niveaux de Gris, on peut attribuer à chaque pixel de l'image une valeur correspondant à la quantité de lumière renvoyée. Cette valeur peut être comprise par exemple entre **0 et 255**. Chaque pixel n'est donc plus représenté par **1 bit**, mais par **1 octet**. Pour cela, il faut que le matériel utilisé pour afficher l'image, soit capable de produire les différents niveaux de gris correspondant.

Le nombre de niveaux de gris dépend du nombre de bits utilisés pour décrire la " couleur " de chaque pixel de l'image. Plus ce nombre est important, plus les niveaux possibles sont nombreux. [2]



Figure I.5 *Image Monochrome (256 couleurs).*

I.4.3 Images en couleurs (Polychromes)

Elle est obtenue par la combinaison de trois couleurs dites primaires : Rouge, vert et bleu(RVB). Chaque couleur est codée comme une image à niveaux de gris, avec des valeurs allant de 0 à 255 .pour $R=V=B=0$ nous auront un noir pur, et pour $R=V=B=255$ nous auront un blanc pur. La représentation des images couleurs se fait donc soit par une image dont la valeur du pixel est une combinaison linéaire des valeurs des trois composantes couleurs, soit par trois images distinctes représentant chacune une composante couleur, on distingue généralement deux types d'images : [5]

-Images 24 bits

-Images à palettes



Figure I.6 *Image polychrome (65536 couleurs)*

I.5 Les caractéristiques d'une image numérique

L'image est un ensemble structuré d'informations caractérisées par les paramètres suivants: [29].

I.5.1. Pixel

Contraction de l'expression anglaise ' Picture Elements' : Eléments d'image, le pixel est le plus petit point de l'image, c'est une valeur numérique représentative des intensités lumineuses. Si le bit est la plus petite unité d'information que peut traiter un ordinateur, le pixel est le plus petit élément que peuvent manipuler les matériels et logiciels sur l'image. La lettre A, par exemple, peut être affichée comme un groupe de pixels dans la figure ci-dessous. [30]




Figure I.7 groupe de pixel formant la lettre A.

I.5.2 La résolution

La résolution est une mesure de la capacité d'un système optique de séparer des signaux proches spatialement et/ou spectralement. La capacité de mesurer une information par télédétection exige la considération prudente de trois types de résolution : spatiale, spectrale et temporelle. [35]

I.5.3 Dimension :

C'est la taille de l'image. Cette dernière se présente sous forme de matrice dont les éléments sont des valeurs numériques représentatives des intensités lumineuses (pixels). Le nombre de lignes de cette matrice multiplié par le nombre de colonnes nous donne le nombre total de pixels dans une image. [6]

I.5.4 La texture

Une texture est une région dans une image numérique qui a des caractéristiques homogènes. Ces caractéristiques sont par exemple un motif basique qui se répète. La texture est composée de Texel, l'équivalent des pixels.[7]

I.5.5 La luminance

C'est le degré de luminosité des points de l'image. Elle est définie aussi comme étant le quotient de l'intensité lumineuse d'une surface par l'aire apparente de cette surface, le mot luminance est substitué au mot brillance, qui correspond à l'éclat d'un objet.

Une bonne luminance se caractérise par :

- Des images lumineuses (brillantes)
- Un bon contraste : Il faut éviter les images où la gamme de contraste tend vers le blanc ou le noir; ces images entraînent des pertes de détails dans les zones sombres ou lumineuses.
- L'absence de parasites. [8]

I.5.6 Le contours

Les contours représentent la frontière entre les objets de l'image, ou la limite entre deux pixels dont les niveaux de gris représentent une différence significative. Les textures décrivent la structure de ceux-ci. L'extraction de contour consiste à identifier dans l'image les points qui séparent deux textures différentes.[7]



Figure I.8 Contour d'une image.

I.5.7 Regions

Groupe de pixel présentant des caractéristique similaires (intensité, mouvement, ect..).[9]

I.5.8 Histogramme d'une image

Un histogramme (traitement statistique de l'image) représente la fréquence desvaleurs d'intensité des pixels dans une image. Ce concept peut être expliqué en considérant une image comme celle montrée dans la figure 1.6 un histogramme h pour une image I des niveaux de gris avec les valeurs d'intensité $I(u, v) \in [0, K - 1]$ contient exactement k entrées. Pour une image de 256 niveaux de gris ($k = 256$), chaque entrée de l'histogramme est définie :

$$\text{Pour } 0 \leq i < k \quad h(i) = \text{card} \{(u, v) / I(u, v) = i\} \quad (\text{I.1})$$

$h(i)$ = le nombre de pixels dans l'image I avec la valeur d'intensité i




Figure I.9 Histogramme d'une image en niveaux de gris

Dans un histogramme les valeurs de pixels les plus présentes dans l'image sont appelés les pics et les valeurs les moins présentes sont les vallées. Les régions vides d'un histogramme indiquent les valeurs de pixels absentes dans l'image. Dans le cas d'une image couleur (par exemple RGB) on obtient trois histogrammes représentant respectivement la distribution des valeurs des composantes Rouges, Bleues et Vertes et un histogramme pour représenter la distribution de la luminance.

I.5.8 .1 Modification d'histogramme

Les méthodes de modification d'histogramme n'affectant pas les formes des régions dans l'image, elles modifient uniquement l'apparence visuelle.

I.5.8 .1.1 Expansion de dynamique

Transformation des niveaux de gris de telle sorte que l'image utilise toute la dynamique entre $[0, 255]$ transformation linéaire

$$I'(i, j) = (I(i, j) - \text{Min}) \times 255 / (\text{Max} - \text{Min}) \quad (\text{I.2})$$

Min : Valeur minimale de niveaux de gris.

Max : Valeur maximale de niveaux de gris.

I.5.8 .1.2 Egalisation d'un histogramme

Transformation des niveaux de gris dont le but est d'équilibrer le mieux possible la distribution de pixels dans la dynamique.




Figure I.10 Egalisation d'un histogramme en niveaux de gris

I.5.8 .1.3 Spécification d'histogramme

Généralisation de l'égalisation d'histogramme, elle permet d'obtenir une distribution d'intensité de l'image voisine d'une distribution spécifiée à l'avance. La distribution de référence peut être soit fixée a priori soit obtenue sur une image ou une portion d'image qui sert d'apprentissage. [10]

I.5.9 Contraste

C'est la différence marquée entre deux régions d'une image, plus précisément entre les régions sombres et les régions claires de cette image. Le contraste est défini en fonction des luminances des deux zones d'images [11]



a) Image mal contrastée



b) Image bien contrastée

Figure I.11 Images avec contraste différent

I.5.10 Le bruit

Un bruit (parasite) dans une image est considéré comme un phénomène de brusque variation de l'intensité d'un pixel par rapport à ses voisins, il provient de l'éclairage des dispositifs optiques et électroniques du capteur.[5]



Figure I.12 *Image sans bruit.*

Figure I.13 *Image avec bruit.*

I.6 Système de traitement d'image

UN système de traitement d'image est généralement composé des unités suivantes :

- UN système d'acquisition et de numérisation qui permet d'effectuer l'échantillonnage et la quantification d'une image.
- Une mémoire de masse pour stocker les images numérisées.
- UN système de visualisation.
- Une unité centrale permettant d'effectuer les différentes opérations de traitement d'images. [8]

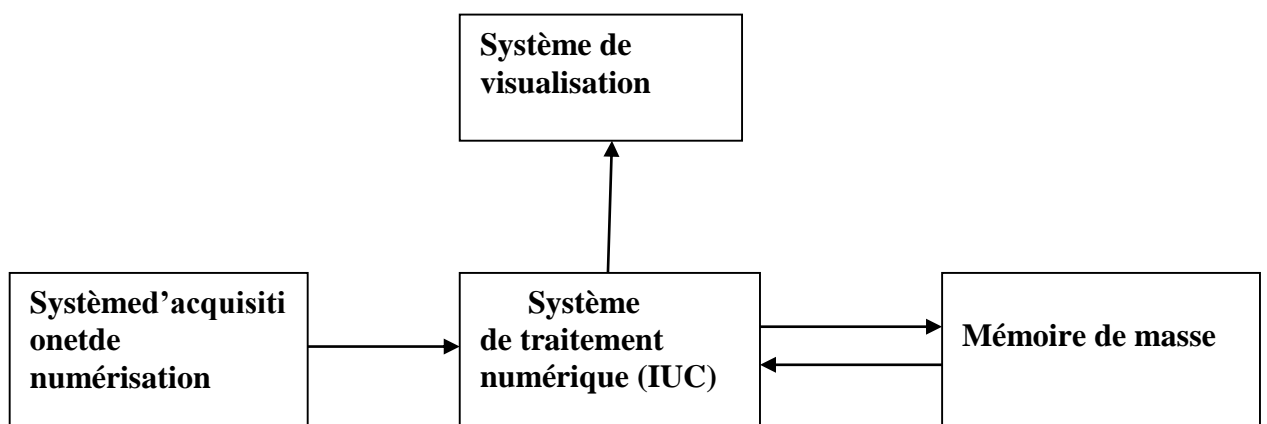


Figure I.14 *Composition d'un système de traitement numérique.*

I.6.1 Acquisition et numérisation :

L'acquisition d'images constitue un des maillons essentiels de toute chaîne de conception et de production d'images. Pour pouvoir manipuler une image sur un système informatique, il est avant tout nécessaire de lui faire subir une transformation qui la rendra lisible et manipulable par ce système. Le passage de cet objet externe (l'image d'origine) à sa représentation interne (dans l'unité de traitement) se fait grâce à une procédure de numérisation. Ces systèmes de saisie, dénommés optiques, peuvent être classés en deux catégories principales : les caméras numériques et les scanners.

I.6.2 Visualisation

Tout système de traitement d'image est doté d'un dispositif de visualisation qui permet l'affichage des images.

L'utilisation de différents types de reconstituteurs permet de transformer le signal numérique qu'est la matrice image en un signal analogique visible par l'oeil de l'observateur. Pour cela, différents types de supports peuvent être employés : moniteur vidéo, clichés photographiques, impression sur papier. Dans tous les cas et pour chaque échantillon de l'image numérique, on recrée un nouvel élément d'image ou un nouveau pixel dont on choisit la forme de façon à reconstituer une image analogique qui soit la plus proche possible de l'image avant numérisation compte tenu des erreurs introduites lors de l'acquisition, de la numérisation et de la transmission .[12]

I.7 traitement numérique des images

Les techniques de traitement sont destinées à l'exploitation des informations contenues dans les images, ceci dans le but d'améliorer la qualité des images et de les rendre plus facilement interprétables, en d'autres termes elles permettent d'augmenter la qualité visuelle de l'image.

I.7.1 Filtrage Numérique

Les images numériques telles qu'elles sont acquises, sont très souvent inexploitable pour le traitement d'images. Elles contiennent des signaux bruités. Pour remédier à cela, différents prétraitements pour l'amélioration ou la correction sont effectués. [5] On peut scinder les filtres en deux grandes catégories :

I.7.1.1 Filtres linéaires

Les filtres linéaires transforment un ensemble de données d'entrée en un ensemble de données de sortie par une convolution bidimensionnelle qui est une opération mathématique. Ils permettent de supprimer le bruit dans l'image. Chaque filtre a une taille $N \times N$ avec N impair. [5] Les filtres linéaires les plus connus sont les filtres passe-bas, passe-haut.

A. Filtre passe-bas (lissage) :

Opération destinée à éliminer le bruit dans l'image ; le filtre passe-bas élimine les signaux de haute fréquence caractérisés par de grandes variations des niveaux de gris entre pixels voisins. Il est appelé aussi filtre de lissage car il adoucit considérablement les contours de l'image. Le principe de ce filtre consiste à remplacer la valeur de chaque pixel par la moyenne effectuée sur un voisinage [26]

B. Filtre Passe-haut (Accentuation) :

Il a les caractéristiques inverses du filtre passe-bas, il atténue les basses fréquences sans toucher à l'information contenue dans les hautes fréquences. Dans ce type de filtre, le masque de convolution peut avoir des coefficients négatifs et positifs mais leur somme doit être égale à zéro [27]

I.7.1.2 Filtres non linéaire

Ils sont conçus pour régler les problèmes des filtres linéaires, Leur principe est le même que celui des filtres linéaires, il s'agit toujours de remplacer la valeur de chaque pixel par la valeur d'une fonction calculée dans son voisinage. La différence majeure, est que cette fonction n'est plus linéaire mais une fonction quelconque (elle peut inclure des opérateurs de comparaisons ou de classification). Les filtres non linéaires les plus connus sont : [8]

A. Filtre médian

Ce filtre est très utilisé pour éliminer le bruit sur une image qui peut être de différentes origines (poussières, petits nuages, baisse momentanée de l'intensité électrique sur les capteurs, ...). L'avantage de ce filtre réside dans le fait qu'il conserve les contours alors que les autres types de filtres ont tendance à les adoucir. [8]

L'algorithme de filtre médian est le suivant :

1. Trier les valeurs par ordre croissant.
2. Remplacer la valeur du pixel centrale par la valeur située au milieu de la triée.
3. Répéter cette opération pour tous les pixels de l'image.




Figure I.15 Principe du filtre médian.

A. Filtre maximum

On applique le même traitement que celui du filtre médian mais la valeur du pixel du centre




Figure I.16 Principe du filtre maximum.

B. Filtre minimum

On applique le même traitement que celui du filtre maximum mais, cette fois, la valeur du pixel du centre comme la montre la figure va être remplacée par le minimum. [8]




Figure I.17 Principe du filtre minimum.

I.7.2 Domaines d'application

Le traitement d'images possède l'aspect multidisciplinaire. On trouve ses applications dans des domaines très variés tels que les télécommunications (T.V., vidéo, publicité,...), la médecine (radiographie, ultrasons,...), biologie, astronomie, géologie, l'industrie (robotique, sécurité), la météorologie, l'architecture, l'imprimerie, l'armement (application militaire).

De nouvelles applications pratiques sont possibles aujourd'hui et touchent tous les domaines d'activités, tels que : métiers du spectacle, de la radio, créations artistiques,... [12]

I.8 Conclusion

Ce chapitre, nous avons voulu à ce qu'il soit une brève introduction aux concepts liés au domaine du traitement d'images. Les différentes définitions qui y sont développées sont celles des connaissances élémentaires de cette discipline, mais combien même elles sont essentielles pour l'initiation aux traitements approfondis des images. Nous pouvons, à présent, aborder au prochain chapitre les techniques de la segmentation d'image.

Chapitre II

Les approches de la segmentation d'images

II.1 Introduction

L'homme sait naturellement séparer des objets dans une image. Pour séparer un objet d'un fond, l'humain se base sur des connaissances de haut niveau qui lui permettent de détecter dans l'image ce qui l'intéresse.

Fondamentalement, la segmentation est un processus qui consiste à découper une image en régions connexes présentant une homogénéité selon un certain critère, comme par exemple la couleur. L'union de ces régions doit redonner l'image initiale. La segmentation est une étape importante pour l'extraction des informations qualitatives de l'image. Elle fournit une description de haut niveau.

II.2 Définition de la segmentation

La segmentation d'image est une phase d'importance capitale dans tout processus de vision par ordinateur. Le processus de segmentation d'une image est le processus qui la découpe en régions dans un but de simplifier la représentation de l'image pour la rendre plus facile à analyser et à interpréter. La segmentation d'images est typiquement utilisée pour localiser des objets ou reconnaître des contours d'objets.

Techniquement la segmentation d'images est un processus d'étiquetage des pixels qui permet de donner un ensemble de pixels couvrant la totalité de l'image ou un ensemble de contours délimitant des régions représentant une certaine homogénéité de couleur, intensité, texture.[31]




Figure II.1 Exemple de segmentation d'image.

À ce jour, il existe (les nombreuses méthodes de segmentation qui sont pratiquement toutes sensibles au bruit. il est donc nécessaire (le commencer par nettoyer l'image en appliquant les filtres usuels d'atténuation le bruit. Parmi les approches (la segmentation les plus connues), on peut citer : la segmentation basée sur le seuillage. La segmentation basée sur les régions et la segmentation basée sur les contours. [12]

II.3 Définition formelle de la segmentation

1. $\cup_{i=1}^n R_i = I$
2. $R_i \cap R_j = \emptyset; \forall i, j \text{ telle que } i \neq j$
3. $p(R_i) = \text{vrai}; \forall i \in \{1, 2, \dots, n\}$
4. $p(R_i \cap R_j) = \text{faux}; \forall i, j \text{ telle que } i \neq j$
5. $R_i \text{ est un composant connexe}; \forall i \in \{1, 2, \dots, n\}$

Formellement, la segmentation d'une image A en régions R_i , $i = 1 \dots n$, est définie par les propriétés suivantes : [12]

- P est un prédicat d'homogénéité.
- La première condition indique que l'union des régions nous ramène à l'image de départ.
- La deuxième indique que deux régions différentes sont disjointes.
- La troisième exprime que les pixels appartenant à une région doivent satisfaire le critère d'homogénéité.
- La quatrième exprime le critère d'homogénéité pour la segmentation en régions disjointes.

II.4 Objectifs de la segmentation

La segmentation d'image sert à :

- Fournir des régions homogènes (selon un critère donné) pour y appliquer un traitement spécifique et interpréter le contenu de l'image : [13]
- Réduire le bruit,
- Extraction des informations qualitatives de l'image, les similitudes (intensités, couleurs, textures, etc.).
- Localiser de manière précise les contours des régions (les arêtes, les changements abruptes, etc.).

Il est difficile de définir d'une manière absolue, une bonne segmentation. La segmentation, souvent, n'est pas une fin en soi, le choix d'une technique est lié à :

- La nature de l'image (éclairage, contours, texture...).
- Aux opérations de la segmentation (compression, reconnaissance de formes, mesures...).
- Aux primitives à extraire (droites, régions, textures...).
- Aux contraintes d'exploitation (temps réel, espace mémoire...).

II.5 Les étapes de segmentation d'images

Les différentes étapes permettant la segmentation d'une image sont résumées dans la figure (Figure II.2) : [13]

- Le prétraitement concerne les images acquises.
- La classification, pour que l'image étant formée d'un certain nombre de propriétés qu'on classera selon des critères appropriés.
- La segmentation est obtenue par extraction des composantes connexes des pixels appartenant à la même classe.
- Analyse des images : extraire des paramètres ou des fonctions représentatives de l'image ou des régions.

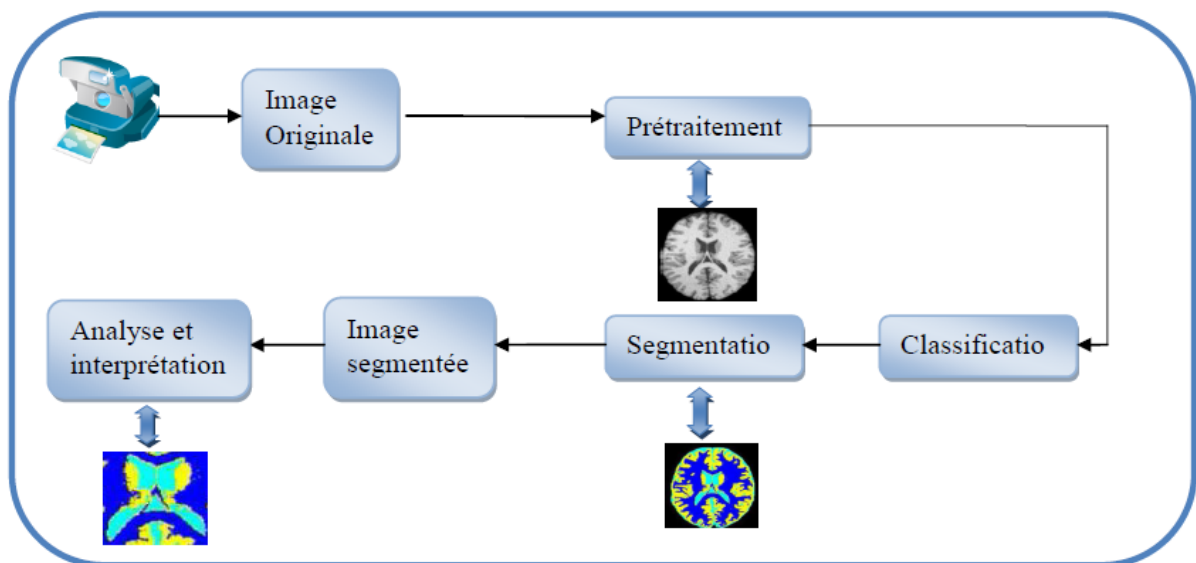


Figure II.2 Etapes de segmentation d'images.

II.6 Segmentation d'images 2D, et au-delà

II.6.1 La segmentation 2D

En ce qui concerne les méthodes de segmentation 2D, elles caractérisent les régions d'intérêts sur des coupes. [13]




Figure II.3 IRM patient 1 (a) , Segmentation patient 1 (b)

II.6 .2 La segmentation 3D

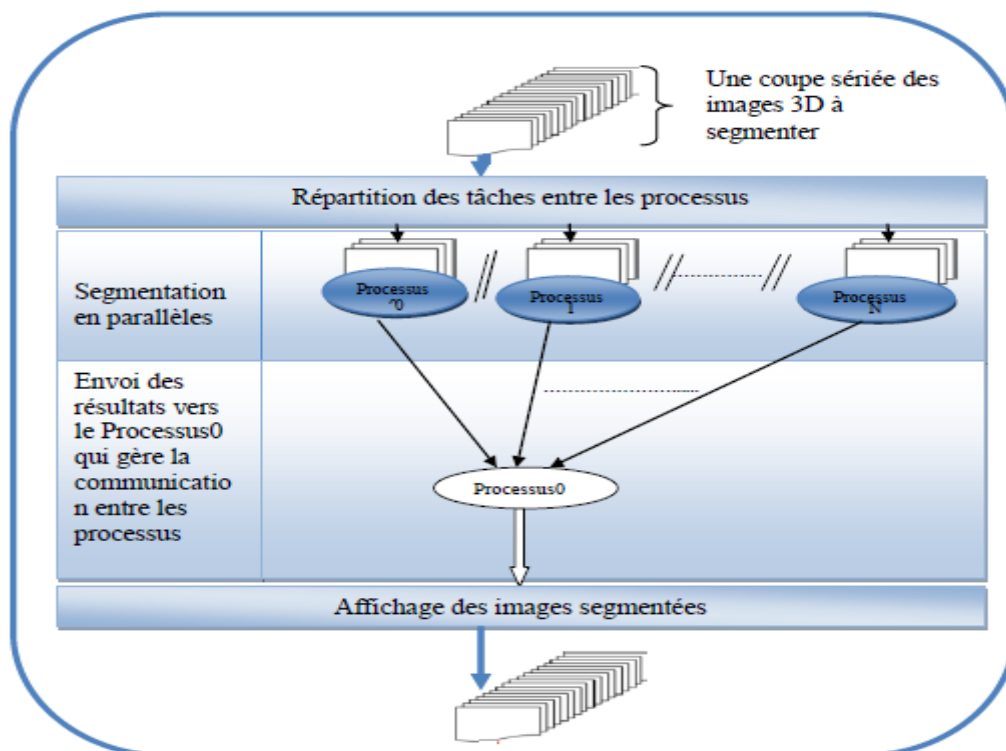


Figure II.4 Segmentations parallèle des images 3D.

Del'héritage des images 2D, il reste les images 3D qui sont souvent produites comme une succession de coupes. Le praticien doit mentalement empiler les coupes pour se faire une représentation du volume des données observées. Cela conduit à une interprétation subjective des données, sans l'aide de l'informatique, ça nécessitait une agilité d'esprit et une expérience importante. La segmentation 3D se fait par une répartition des tâches entre les processus qui la gère. [13]

II.7 Différentes approches de segmentation

La segmentation est un vaste sujet d'étude et fait partie des grands thèmes de l'imagerie numérique. A ce titre, de nombreuses publications font état de segmentations. Comment préférer l'une ou l'autre est un débat ouvert qui fait rage dans bien des laboratoires. En effet, pour valider correctement une segmentation d'objets naturels, comme en imagerie médicale, il faut disposer de la vérité terrain ; ce qui est bien difficile dans le cas de la segmentation, car comment définir de façon précise où commencent et où s'arrêtent les objets sur une image ? Il n'y a donc pas une mais des segmentations possibles sur une même image et elles sont bien souvent subjectives. De même, selon ce que nous voulons segmenter, certaines techniques seront plus à même d'y parvenir.[32]

II.8 Approches Contours

Dans une image, les variations (d'intensité, de couleur, de texture...) représentent des changements de propriétés physiques ou géométriques de la scène ou de l'objet observé. Dans un grand nombre de cas, ces variations des propriétés sont des informations importantes pour les opérations de la segmentation. Un contour est une zone de transition séparant deux régions homogènes due à des discontinuités de profondeur et de réflectance de la scène observée [37]. Elles constituent les frontières de régions correspondant à des bords ou parties d'objets de la scène [38].

De telles méthodes existent depuis longtemps et elles sont les premières méthodes à base de géométrie. Elles ont été développées au milieu des années 80[39].

Les contours extraits ne sont généralement pas fermés ou bien continus, il est souvent nécessaire d'associer une méthode de suivi ou de fermeture de contours selon le résultat.




Figure II.5 quelques modèles de contours.

- escompté. Marche d'escalier : le contour est net (contour idéal).
- Rampe : le contour est plus flou.
- Toit : il s'agit d'une ligne sur un fond uniforme.

Nous présentons dans ce qui suit les différentes méthodes adaptées pour la détection des contours dans des images en niveaux de gris. Pour ces dernières, deux familles de méthodes sont distinguées.

II.8.1 Méthodes dérivatives

Les méthodes dérivatives sont les plus utilisées pour détecter des transitions d'intensité par différenciation numérique (Première et deuxième dérivé). A chaque position, un opérateur est appliqué afin de détecter les transitions significatives au niveau de l'attribut de discontinuité choisi. Le résultat est une image binaire constituée de points de contours et de points non-contours. [5]




Figure II.6 Contour et ses dérivées.

De nombreuses techniques d'extraction de contours existent dans la littérature. Elles peuvent être classées comme suit [14]:

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

II.8.1.1 L'approche Gradient

On utilise la première dérivée pour calculer le gradient. Le gradient, en un pixel, est un vecteur caractérisé par une amplitude et une direction.

L'approximation des deux dérivées est donnée par la relation suivante :

$$\frac{\partial I(x,y)}{\partial x} = I(x+1,y) - I(x,y), \frac{\partial I(x,y)}{\partial y} = I(x,y+1) - I(x,y) \quad (I.3)$$

Le module :

$$G(x,y) = \|\nabla I(x,y)\| = \sqrt{G_x(x,y)^2 + G_y(x,y)^2} \quad (I.4)$$

La direction (argument)

$$\arg G(x,y) = \arctan\left(\frac{G_y(x,y)}{G_x(x,y)}\right) \quad (I.5)$$

Il existe plusieurs opérateurs de gradient Parmi ses opérateurs, il y a les masques de Roberts, de Prewitt et de Sobel ...etc. [5]

a. Opérateurs de Sobel et Prewitt :

Les opérateurs de "Sobel" et de "Prewitt" permettent d'estimer la norme du gradient bidimensionnel d'une image en niveau de gris. Ces opérateurs consistent en une paire de masques de convolution 3×3.

Pour ces opérateurs les dérivées directionnelles horizontale et verticale s'expriment sous la forme : [15]

$$\frac{\Delta I}{\Delta j} = h_j * I(i,j) \text{ et } \frac{\Delta I}{\Delta i} = h_i * I(i,j) \quad (I.6)$$

$$\text{Avec : } h_j = \begin{bmatrix} 1 & 0 & -1 \\ c & 0 & -c \\ 1 & 0 & -1 \end{bmatrix} \text{ et } h_i = \begin{bmatrix} 1 & c & 1 \\ 0 & 0 & 0 \\ -1 & -c & -1 \end{bmatrix}$$

Les matrices h_j et h_i sont appelées masques, Les masques de Prewitt sont définis par $c=1$ et les masques de Sobel par $c=2$.

b. Opérateur de Roberts (1965)

Le détecteur de Roberts permet de calculer le gradient bidimensionnel d'une image de manière simple et rapide. Ce principe ne diffère pas beaucoup de celui des opérateurs de "Prewitt" et "Sobel". [5]

Les masques de convolution de Robert sont :

$$\begin{bmatrix} 1 & 0 \\ 0 & -1 \end{bmatrix} \text{ et } \begin{bmatrix} 0 & 1 \\ -1 & 0 \end{bmatrix}$$

La figure suivante nous montre les contours détectés par ces filtres :




Figure II.7 Détection de contour par les différents filtres.

II.8.1.2 L'approche Laplacien

Dans cette approche, l'extraction des contours est basée sur le calcul des dérivées secondes, cela signifie que le Laplacien [5]

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

L'approximation des deux dérivées est donnée par la relation suivante :

$$\nabla^2 f = f(x + 1, y) + f(x - 1, y) + f(x, y - 1) + f(x, y + 1) - 4f(x, y)$$

Les plus simples opérateurs du Laplacien est donnée par l'application des masque suivant :

- Laplacien en connexité 4 :

$$\begin{pmatrix} 0 & 1 & 0 \\ 1 & -4 & 1 \\ 0 & 1 & 0 \end{pmatrix}$$

- Laplacien en connexité 8 :

$$\begin{pmatrix} 1 & 1 & 1 \\ 1 & -8 & 1 \\ 1 & 1 & 1 \end{pmatrix}$$

La figure suivante représente la détection de contour en utilisant le Laplacien :



Figure II.8 Image originale (à gauche), contour détecté par le Laplacien.

II.8.2 Méthodes analytiques

II.8.2.1 Approche de Canny et Deriche

Elle consiste à trouver un filtre optimal satisfaisant les 3 contraintes suivantes :

- **Une bonne détection** : faible probabilité d'oublier un vrai point de contour et une faible probabilité de marquer un point image comme contour alors qu'il ne l'est pas.

- **Une bonne localisation** : les points contours doivent être le plus près possibles de leur position réelle dans l'image.
- **Une réponse unique** : à un contour unique : un point de contour ne doit être détecté qu'une seule fois par le filtre mis en œuvre.

Le détecteur de contour de Canny est le plus utilisé. Il est basé sur trois critères : la détection (robustesse au bruit), la localisation (précision de la localisation du point contour), l'unicité (une seule réponse par contour) [16]

Au filtre de Canny, Deriche a proposé un autre filtre (condition initiale différente) qui permet une simplification de son implémentation nous préférons souvent le détecteur de Deriche, qui répond exactement aux mêmes critères de qualité que celui de Canny. [17]

II.8.3 Méthodes déformables

Les modèles déformables, introduits par Kass sont aussi connus sous les noms de « snakes » ou « contours actifs ». L'intérêt principal des contours actifs est de détecter des objets dans une image en utilisant les techniques d'évolution de courbes. L'idée est de partir d'une courbe initiale, généralement un carré ou un cercle, et de la déformer jusqu'à obtenir le contour de l'objet.

En effet, celui-ci présente quelques inconvénients tels que la sensibilité à l'initialisation, au bruit, et le réglage difficile de ses différents paramètres. [18]

II.8.3.1 Contours actifs

Les contours actifs tirent leur origine des modèles élastiques, mais la communauté s'accorde à les attribuer à l'équipe Kass, Witkin et Terzopoulos, qui introduisirent les Snakes ou courbes minimisantes. Les snakes tiennent leur nom de leur aptitude à se déformer comme des serpents. L'approche est variationnelle, c'est à dire que l'équation d'évolution du contour actif se déduit de la minimisation d'une énergie modélisant l'objet d'intérêt.

Depuis la publication de cette équipe, les modèles déformables sont devenus un sujet très important pour la communauté du traitement d'images. [2]

II.8.3.1.1 Principe de fonctionnement des contours actifs

Un contour actif est une courbe définie dans l'image et qui est capable de se mouvoir sous l'influence de plusieurs forces qui vont la tirer ou la pousser vers la forme. Un snake consiste à placer aux alentours de l'objet à détecter une ligne initiale de contour,

l'évolution se fait à travers un processus itératif qui déforme la courbe à chaque itération jusqu'à sa position finale.

II.8.4 La limite de segmentation par contour

Les principales limites des méthodes de détection de contour sont les suivantes [14] :

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

II.9 Approche région

Les méthodes de l'approche région cherchent à différencier les régions en utilisant les propriétés de l'image telles que la couleur, la texture, la forme... Ces méthodes utilisent principalement les critères de décision pour segmenter l'image en différentes régions selon la similarité des pixels [33]. Il existe plusieurs méthodes telles que la segmentation par croissance de région, par division de région, et par fusion de région que nous présentons ci-dessous.

II.9.1 Croissance de région (région growing)

Les méthodes de croissance de région, également appelées approches ascendantes, est une technique qui consiste à agréger les pixels aux régions selon un double critère d'homogénéité et d'adjacence [42]. Les points voisins du germe sont successivement examinés ; s'ils vérifient le critère d'agrégation, ils sont inclus à la région et deviennent à leur tour un germe ; dans le cas contraire, ils sont rejetés. Le critère est le plus souvent un critère local basé sur les niveaux radiométriques des points. Le processus s'arrête lorsque tous les pixels adjacents aux régions ont été affectés. [43]



Figure II.9 Croissance progressive des régions.

Parmi les avantages de cette technique, nous pouvons citer : [2]

- La simplicité et la rapidité de la méthode.
- La segmentation d'objet à topologie complexe.
- La préservation de la forme de chaque région de l'image.
- Cependant, il existe plusieurs inconvénients comme :
- L'influence du choix des germes initiaux et du critère d'homogénéité sur le résultat de la segmentation.
- Une mauvaise sélection des germes ou un choix du critère de similarité mal adapté peuvent entraîner des phénomènes de sous-segmentation ou de sur-segmentation.
- Il peut y avoir des pixels qui ne peuvent pas être classés.

II.9.2 Segmentation par fusion de régions (Merge)

Les techniques de réunion sont des méthodes ascendantes où tous les pixels sont visités. Pour chaque voisinage de pixel, un prédicat P est testé. S'il est vérifié les pixels correspondants sont regroupés dans une région. Après le parcours de toute l'image, les groupes de voisinages se voient appliquer le même test, et sont réunis si P est vérifié. Le processus est itéré jusqu'à satisfaction d'un critère d'arrêt.[44]

II.9.3 Segmentation par division de régions (Split)

La division consiste à partitionner l'image en régions homogènes selon un critère donné. Le principe de cette technique est de considérer l'image elle-même comme région initiale, qui par la suite est divisée en régions. Le processus de division est réitéré sur chaque nouvelle région (issue de la division) jusqu'à l'obtention de classes homogènes [14].

Figure II.11 Agrégation itérative des blocs similaires au bloc 1.




Figure II.10 Décompositions successives des blocs.

Cette méthode présente un inconvénient majeur qui est la sur-segmentation. Toutefois, ce problème peut être résolu en utilisant la méthode de division-fusion que nous présentons dans ce qui suit.

II.9.4 Segmentation par division-fusion (Split and Merge)

Son principe est de combiner les deux dernières méthodes présentées afin de pallier à leurs inconvénients de la manière suivante : une première étape de division donne comme résultat, une image divisée en plusieurs régions (Figure II.15). Par la suite, une étape de fusion intervient afin de corriger le résultat obtenu par la première étape, en regroupant les régions similaires (Figure II.12). Ce procédé est répété jusqu'à l'obtention d'une segmentation. [45]




Figure II.11 : La décomposition en 4 peut faire apparaître des blocs similaires.





Figure II.12 Les décompositions successives peuvent faire apparaître des blocs similaires.




Les inconvénients de cette méthode se situent à trois niveaux :

- Les régions obtenues ne correspondent pas, dans tous les cas, aux objets représentés dans l'image.
- Les limites des régions obtenues sont habituellement imprécises et ne coïncident pas exactement aux limites des objets de l'image.
- La difficulté d'identifier les critères pour agréger les pixels ou pour fusionner et diviser les régions. [5]

II.10 Segmentation par seuillage


II. 10.1 Définition du seuillage

Le seuillage est la technique de segmentation la plus répandue pour extraire les objets du fond de l'image [36]. Elle est l'opérateur qui associe à chaque point de l'image une classe de luminance. Le seuillage est réalisé après comparaison des luminances à un ou plusieurs seuils. Cette technique tente de déterminer les classes de pixels par l'analyse des histogrammes monodimensionnels, le plus souvent les seuils sont déterminés à l'aide de ces analyses localement ou globalement à l'image ou au volume [40]. Dans le cas d'une image composée d'une ou plusieurs régions de même type, et d'un fond visuellement différent, l'histogramme est bimodal et il est possible de séparer les régions du fond par un simple seuil qui se situe sur la vallée entre les deux modes (figure II.12). Si l'image est constituée de régions ayant des caractéristiques différentes, son histogramme est multimodal (figure II.13), tels que chacun des modes correspond à une région. Le seuillage est alors défini comme le problème de trouver le minimum entre deux modes adjacents c'est-à-dire les vallées. Les pixels ayant des niveaux de gris entre deux vallées sont alors assignés à la même région. [41]



$$g(x,y) = \begin{cases} 0 & \text{si } f(x,y) < T \\ 1 & \text{si } f(x,y) \geq T \end{cases}$$

Figure II.12 Seuillage simple d'un histogramme.



$$G(x,y) = \begin{cases} 2 & \text{si } f(x,y) \geq T2 \\ 1 & \text{si } T1 \leq f(x,y) < T2 \\ 0 & \text{si } f(x,y) < T1 \end{cases}$$

Figure II.13 Seuillage multiple d'un histogramme.

La segmentation par seuillage d'histogramme constitue un cas particulier de la segmentation par classification. Elle permet de répartir les pixels en classes en fonction de leurs niveaux de gris. Les classes sont alors délimitées par des seuils.

Les méthodes de seuillage peuvent être : Seuillage globale et seuillage local, manuelle.[2]

II. 10.2 seuillage globale

Seuillage globale : un seuil pour toute l'image, elle consiste à comparer le niveau de gris de chaque pixel x_i de l'image avec un seuil global fixe T (par exemple 127). On note b_i la nouvelle valeur du pixel, le seuillage est donné par l'expression suivante :

$$b_i = 255 \text{ si } x_i \geq T \text{ et } b_i = 0 \text{ si } x_i < T$$

II. 10.3 seuillage locale

Seuillage local ou adaptatif : un seuil pour une portion de l'image. Les méthodes de seuillage locale prennent en considération la valeur des pixels voisins pour le calcul des seuils.[2]

II.11 Généralités sur la segmentation des images médicales :

Loin du problème de reconstruction, la segmentation automatique est un objectif en soi-même en imagerie médicale, elle joue un rôle très vital dans la mesure où elle permet d'extraire des structures anatomiques spécifiques ou la localisation de certaines pathologies au sein d'une séquence d'images numériques ce qui apporte une amélioration très intéressante au processus de diagnostic médical. La segmentation automatique des images médicales constitue un pas important pour l'établissement d'un système d'aide au diagnostic automatique des images médicales.

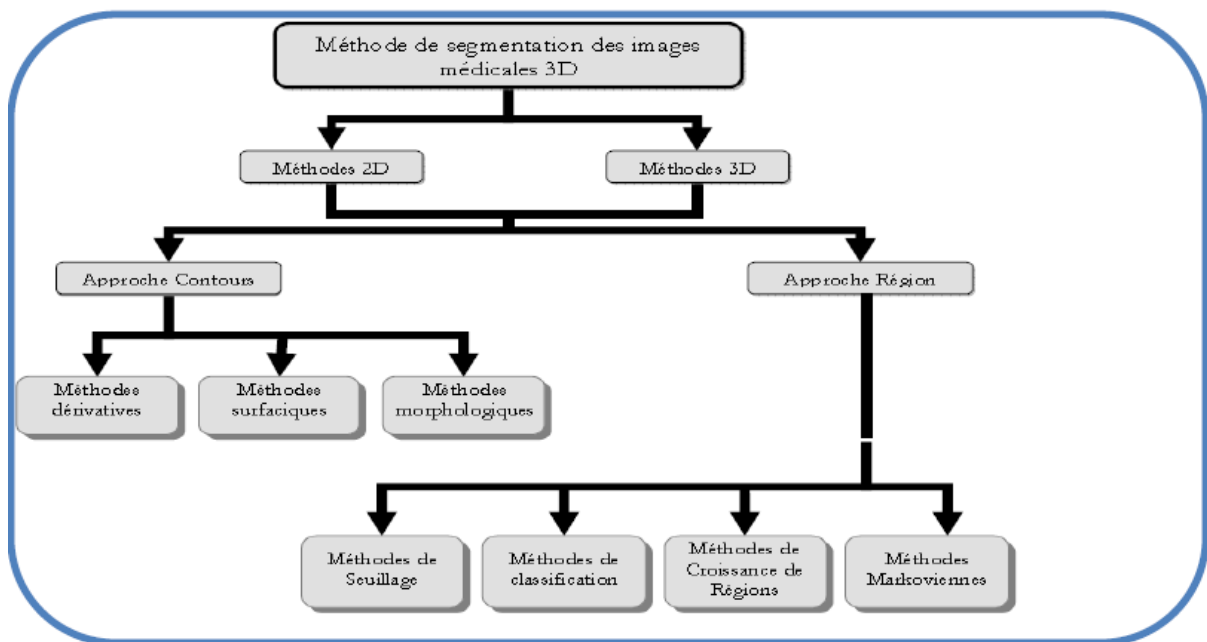


Figure II.14 Principales méthodes de segmentation des images médicales.

Le but est de segmenter la zone d'intérêt définie par le médecin pour lui permettre, par calculs, d'affiner son diagnostic. La segmentation doit donc être précise autour de la zone d'intérêt et ne doit pas être perturbée par le bruit de l'image.[13]

II.12 Conclusion

Nous avons tenté dans ce chapitre de regrouper les techniques de segmentation d'images en trois approches : approche par extraction de régions, approche par détection de contours et une approche par classification. Bien qu'elles aient toutes des avantages, elles présentent également plusieurs inconvénients. Et comme la segmentation d'une image peut être considérée comme un problème d'optimisation, dans le chapitre qui suit, nous présenterons différentes segmentations d'image par **champ de Markov**.

Chapitre III

Segmentation par champ aléatoire de Markov (MRF)

III.1 Introduction :

A l'heure actuelle, il n'existe guère d'applications commerciales de méthode efficace de segmentation d'images sur laquelle on peut baser les traitements ultérieurs. La technique qui s'est avérée la meilleure en imagerie médicale pour le moment est l'application des chaînes de Markov. On verra à la partie 3 une présentation succincte de la mise en œuvre de cette technique. Notons que les modèles de Markov cachés sont une approche prometteuse dans différents domaines d'applications où on envisage de traiter des données quantifiées qui peuvent être partiellement erronées comme par exemple :

- La reconnaissance d'images : caractères, empreintes digitales, ...
- la recherche de motifs et de séquences dans les gènes.

III.1.1 Historique :

La modélisation stochastique permet l'utilisation des modèles probabilistes pour traiter les problèmes à information incertaine ou incomplète. Ainsi, les modèles de Markov connaissent un regain d'intérêt tant dans leurs aspects théoriques qu'appliqués.

La théorie des chaînes de Markov est née en 1913, une première application a été développée par Markov pour analyser le langage. Ces travaux ont été utilisés régulièrement mais les premières applications exploitables furent réalisées dans les années 60, telles que les modèles probabilistes d'urnes par Neuwirth, le calcul direct du maximum de vraisemblance ou l'observation de la suite d'états dans une chaîne de Markov. Ceci a permis à la communauté scientifique d'exploiter pleinement le potentiel de ces modèles. C'est dans les années 70 que des chercheurs ont apporté des algorithmes puissants permettant de résoudre les problèmes de reconnaissance, d'analyse et d'apprentissage.

Depuis 1975, les HMM sont utilisés dans de nombreuses applications, principalement dans le domaine de la parole. Ces applications ne se contentent pas de s'appuyer sur la théorie des Modèles de Markov Cachés, mais développent plusieurs extensions théoriques dans le but d'améliorer les modèles. C'est ce qui en a fait leur succès. [46]

III. 1 Modèles de Markov cachés :

III. 1.2. Définitions des éléments d'un modèle MMC :

Une chaîne de Markov Cachée λ décrit un système qui à chaque instant se trouve dans un des N états d'un ensemble $\{S_1, S_2, \dots, S_i, \dots, S_N\}$: il s'agit donc d'un automate probabiliste d'états finis constitué de N états.




Figure III.1 exemple d'automate probabiliste d'états finis (composé ici de 3 états).

III.1.3 Formalisme :

Un automate de Markov à états cachés est un quadruplet $\{S, D, O, B\}$ des ensembles décrits suivant :

- S_i l'état i
- D_i la probabilité que S_i soit l'état initial
- $O(S_i, S_j)$ la probabilité de la transition $S_i \rightarrow S_j$
- $B(S_i, o_i)$ la probabilité d'émettre un signal o_i étant dans l'état S_i

Un processus aléatoire gère la transition d'état à état, mais l'état du système n'est pas observable (il est « caché »), on ne voit que les émissions de cet état : les observations. Autrement dit, au temps t le système est dans l'état q_t (invisible) et émet l'observation O_t (visible).

La probabilité de transition d'un état S_i à un état S_j est donnée ; nous l'appellerons $O(S_i, S_j)$:

$$O(S_i, S_j) = p(st = S_j \setminus st - 1 = S_i), \text{ tel que : } \sum_{j=1}^N O(S_i, S_j) = 1. \quad \text{III. 1}$$

On se donne aussi $d(S_i)$ la probabilité que l'automate soit dans l'état S_i à l'instant initial :

$$d(S_i) = p(S_1 = S_i), \text{ tel que : } \sum_{i=1}^N d(S_i) = 1 \quad \text{III. 2}$$

La probabilité pour que l'automate émette un signal o_i lorsqu'il est dans l'état S_i sera notée $b(S_i, o_i)$:




Figure III.2 Détail de probabilité de transition et d'émission d'une donnée dans le modèle de Markov caché.

$$b(S_i, o_t) = P(O_t = o_i \setminus S_t = s_i), \text{ tel que : } \sum_{i=1}^N b(S_i, o_i) = 1 \tag{III.3}$$

L'adjectif « caché » employé pour caractériser le modèle traduit le fait que l'émission d'une donnée à partir d'un état est aléatoire. C'est ce caractère aléatoire des mesures qui, ajouté aux propriétés des processus markoviens fait la souplesse et la puissance de l'approche proposée par F. Jelinek. [13]

Ces observations O_t peuvent prendre leurs valeurs dans un ensemble fini de valeurs discrètes ou de symboles, ou dans un ensemble continu et infini ; dans ce dernier cas le principe reste le même, avec des distributions de probabilité remplacées par des densités de probabilités, comme on effectue alors des tirages directement sur cette courbe de densité, on parle alors de vraisemblance, et non plus de probabilités.

On définit une vraisemblance L pour une fonction de densité f , par rapport à la probabilité P par : [13]

$$L(X_1 \dots \dots X_N) = \prod_{i=1}^N f(X_i) \tag{III.4}$$

$$P\left(\text{arg} = X_1 \in \left[x_1 - \frac{\varepsilon}{2}; x_2 + \frac{\varepsilon}{2}\right], \dots, X_N \in \left[X_N - \frac{\varepsilon}{2}; X_N + \frac{\varepsilon}{2}\right]\right) = \prod_{i=1}^N \int_{X_i - \frac{\varepsilon}{2}}^{X_i + \frac{\varepsilon}{2}} f(X_i) dX_i \tag{III.5}$$

$$P(\text{arg}) = \prod_{i=1}^N f(X_i) \cdot \varepsilon \tag{III.6}$$

$$P(\text{arg}) = \varepsilon L(X_1, \dots, X_N) \tag{III.8}$$

III.1.4 Les champs de Markov cachés :

Soit X un champ aléatoire indexé par l'ensemble S . X est dit champ Markovien associé au système de voisinages V si et seulement si [19]

$$P(X = x) > 0 \quad (\text{III. 9})$$

$$P(\mathbf{X}_S = \mathbf{x}_S | (X_t = x_{st})_{t \in S, t \neq s}) = P(\mathbf{X}_S = \mathbf{x}_S | (X_t = x_{st})_{t \in V_s}) \quad (\text{III. 10})$$

Les relations élémentaires à l'intérieur du système de voisinage sont données par l'ensemble C des cliques. La (Figure III.3) montre un système de voisinage associé aux cliques de 4 connexions.




Figure III.3 Voisinage de pixel et clique de 4 connexions.

Le théorème de Hammersley-Clifford rend possible de relier les probabilités locales et globales. En fait les probabilités a priori conditionnelles locales peuvent s'écrire [19] :

$$P(X_S = x_S | (X_t = x_t)_{t \in V_S}) = \frac{1}{Z_S} \exp(-U(x_S, (x_t)_{t \in V_S})) \quad (\text{III. 11})$$

$$Z_S = \sum_{\omega_i \in \Omega} U_S(\omega_i, (x_t)_{t \in V_S}) \quad (\text{III. 12})$$

Où Z_S est le facteur de normalisation et $U_S(X_S, (X_t)_{t \in V_S})$ est la fonction d'énergie locale. Il y a plusieurs méthodes de calcul $U_S(X_S, (X_t)_{t \in V_S})$ incluant le modèle d'Ising, et le modèle de Potts, pour simplifier, on se limite au modèle de Potts, 4 connexions (où un site a 4 voisins) et des cliques d'ordre 2 définies comme :

$$U(x) = \alpha \sum_{(s,t) \in S} (1 - \delta(x_s, x_t)) \quad (\text{III. 13})$$

$$\delta(x_s, x_t) = \begin{cases} 1 & \text{si } x_s \neq x_t \\ 0 & \text{sinon} \end{cases}$$

Où δ est le symbole de Kronecker. Par conséquent, $U_S(X_S, (X_t)_{t \in V_S})$ est le nombre de pixel $t \in V_s$ pour lesquelles $x_t \neq x_s$, multiplié par un paramètre de régularité λ . Ce modèle a priori pénalise deux sites voisins possédant des étiquettes différentes, le poids de cette

pénalité est de valeur fixée λ . On suppose que le paramètre spatial λ est positif afin de favoriser les cliques homogènes. L'énergie U dans (4) est calculée de façon similaire, sauf qu'on somme les potentiels des cliques d'ordre deux horizontaux et verticaux dans l'image.

La règle de Bayes :

$$P(X = x|Y = y) = \frac{P(Y = y|X = x)P(X = x)}{P(Y = y)} \quad (\text{III. 14})$$

et l'indépendance conditionnelle des échantillons nous permet d'écrire la probabilité a posteriori comme :

$$P(X = x|Y = y) = \frac{1}{Z'} \exp\left(-U(x) + \sum_{s \in S} \log f_{Xs}(y_s)\right) \quad (\text{III. 15})$$

Les distributions a posteriori conditionnelles locales correspondantes peuvent s'écrire comme :

$$P(X_s = x_s | Y_s = y_s (X_t = x_{st})_{t \in V_s}) = \frac{1}{Z'_s} \exp(-U(x_s, (x_{st})_{t \in V_s}) + \log f_{Xs}(y_s)) \quad (\text{III. 16})$$

Où Z' et Z'_s sont des facteurs de normalisations obtenus par sommation de tous les dénominateurs possibles similaires à Z et Z_s . Les distributions $f_{Xs}(y_s)$ sont les termes d'attache aux données tandis que les $U_s(x)$ sont les termes portant l'information a priori. Substituons $U'(X) = U(X) - \sum_{s \in S} \log f_{Xs}(y_s)$ dans (8), on remarque que X conditionnel à Y est un champ de Gibbs.

Il n'est pas possible de créer des réalisations a posteriori de X directement à partir de (8), mais elles peuvent être approximées itérativement par l'algorithme de Metropolis ou l'échantillonneur de Gibbs. Ici, nous considérons seulement le dernier.[19]




Figure III.4 : Parcours d'Hilbert-Peano

III.1.4.1 les probabilités conjointes

$$C_{ij} = P(X_n = \omega_i, X_{n+1} = \omega_j) \quad (\text{III.17})$$

la loi initiale

π_i représente la probabilité que l'état de départ du modèle soit la classe ω_i

$$\pi_i = P(X_1 = \omega_i) = \sum_{j=1}^k C_{ij} \quad (\text{III.18})$$

III.1.4.2 Les probabilités de transition

a_{ij} représente la probabilité que le modèle évolue de la classe ω_i à la classe ω_j

$$a_{ij} = P(X_{n+1} = \omega_j | X_n = \omega_i) = \frac{c_{ij}}{\sum_{j=1}^k c_{ij}} \quad (\text{III.19})$$

III.1.4.3 Probabilités Forward et Backward

Les probabilités appelées Forward et Backward :

$$\alpha_n(i) = P(X_1 = \omega_i, Y_1 = y_1, \dots, Y_n = y_n) \quad (\text{III.20})$$

et

$$\beta_n(i) = P(Y_{n+1} = y_{n+1}, Y_N = y_N | X_n = \omega_i) \quad (\text{III.21})$$

Peuvent être facilement calculées récursivement. Pour ce faire, la probabilité jointe est remplacée par la probabilité a posteriori

$$\alpha_n(i) = P(X_1 = \omega_i | Y_1 = y_1, \dots, Y_n = y_n) \quad (\text{III.22})$$

$$\beta_n(i) = \frac{P(Y_{n+1} = y_{n+1}, \dots, Y_N = y_N | X_n = \omega_i)}{P(Y_{n+1} = y_{n+1}, \dots, Y_N = y_N | Y_1 = y_1, \dots, Y_n = y_n)} \quad (\text{III.23})$$

III.1.5 Modèle Markovien Cachée pour la segmentation d'images

Soit S un ensemble fini correspondant à une image de N pixels. On considère deux processus aléatoires $X=(X_s)_{s \in S}$ et $Y=(Y_s)_{s \in S}$. Y représente l'image observée et X représente une classe d'image inconnue. Chaque variable aléatoire X_s prend ses valeurs dans l'ensemble fini des classes $\Omega = \{\omega_1, \dots, \omega_K\}$, alors que chaque Y_s est une valeur réelle. On dénote la réalisation de X et Y par $x=(x_1, \dots, x_N)$ et $y=(y_1, \dots, y_N)$ respectivement. On suppose ici que les variables aléatoires $Y=(Y_s)_{s \in S}$ sont conditionnellement indépendants à X , et la distribution de chaque Y_s conditionnelle à X est égale à sa distribution conditionnelle à X_s . D'ici, toutes les distributions de Y sachant X sont déterminées par les K distributions de Y_s

avec $X_s = \omega_1, \dots, X_s = \omega_K$ qui sera dénoté f_1, \dots, f_K (1) (6) :

$$P(Y = y | X = x) = \prod_{s \in S} P(Y_s = y_s | X_s = x_s) = \prod_{s \in S} f_{X_s}(y_s) \quad (\text{III.24})$$

X est dans la plupart des cas mieux décrit par un modèle markovien. Généralement, nous référons comme étant un modèle de Markov caché, lorsque X n'est pas directement observable. Le problème de classification consiste à estimer $X=x$ à partir de l'observation $Y=y$. [20]

III.1. 6 Les Chaines de Markov cachés

Dans le cadre des chaînes de Markov, une image 2D peut être facilement transformée en une image 1D, par exemple en parcourant l'image ligne par ligne ou colonne par colonne. Une autre alternative est d'utiliser le parcours de Hilbert-Peano, présentée dans la Figure III.4). Selon la définition, X est une chaîne de Markov si pour $1 < n < N$ [1].

(10)

$$P(X_n = x_n | X_1 = x_1, \dots, X_{n-1} = x_{n-1}) = P(X_n = x_n | X_{n-1} = x_{n-1}) \quad (\text{III. 25})$$

Une chaîne de Markov homogène sera par conséquent entièrement déterminée par la donnée de sa distribution X_1 , dénoté par π , et l'ensemble des matrices de transitions $(A^n)_{1 \leq n < N}$, dont ses éléments sont

$$a_{ij}^n = P(X_{n+1} = \omega_j | X_n = \omega_i) \quad \text{III. 26}$$

La chaîne étant stationnaire, ces probabilités sont déduites des probabilités conjointes qui sont indépendante de n . [19]

III.2 Modélisation probabiliste de l'image

L'image dont nous disposons va être considérée comme une réalisation d'un champ aléatoire. Soit s un site de l'image, on peut en effet lui associer une variable aléatoire X_s prenant ses valeurs dans E . Le niveau de gris x_s en s n'est ainsi qu'une réalisation de la v.a. X_s . On définit alors le champ aléatoire $X = (X_s, X_t, \dots)$ prenant ses valeurs dans $\Omega = E^s$. On trouvera aussi le terme de processus aléatoire pour X ; en toute rigueur, "processus" devrait être réservée au cas d'un ensemble d'indexations continues, et champ au cas discret.

Dans ce cadre probabiliste, l'image considérée est simplement une réalisation x du champ. La probabilité globale de x , $P(X = x)$, traduit la vraisemblance de l'image et la probabilité conditionnelle locale $P[X_s = x_s / X_t = x_t, t = s]$ permet de mesurer le lien statistique entre le pixel s et le reste de l'image. L'hypothèse markovienne permet d'évaluer ces quantités. Notons que nous nous plaçons dans le cas où E , l'espace de valeurs des descripteurs, est quantifié, ce qui nous permet de manipuler des probabilités. Dans le cas où cet espace est continu, il faut remplacer P par une densité de probabilité. [21] Comme on a mentionné dans le premier chapitre la notion de clique dans les images, on indique que chaque clique $c \in C$ est associé un potentiel U_c , sa valeur dépend des descripteurs des pixels constituant la clique. L'énergie globale de l'image est alors définie comme la somme des potentiels de toutes les cliques : [22]

$$U = \sum_{c \in C} U_c \quad (\text{III. 27})$$

L'énergie locale en un site s est définie comme la somme des potentiels de toutes les cliques auxquelles il appartient : [22]

$$U_s = \sum_{c \in C / s \in c} U_c \quad (\text{III. 28})$$

III.3 Champs de Markov et champs de Gibbs

III.3.1 Les Champs aléatoires de Markov en Analyse d'Images

A vrai dire, La modélisation par les champs aléatoires de Markov (MRFs) est un modèle statistique dans lequel on peut intégrer une méthode de segmentation.

La théorie des (MRF) fournit un outil assez consistant pour modéliser les dépendances contextuelles qu'on peut retrouver dans une image exprimées par les pixels et leurs propriétés spatiales corrélées. Ces contraintes contextuelles sont d'importance majeure pour l'interprétation des informations visuelles apportées par une image donnée. De plus, les MRF sont réputés par une force aux bruits dans une application de traitement de signal.

III.3.1.1 Le fondateur de la discipline

Andrei Andreevich Markov (1856-1922) un mathématicien russe. Ses travaux sur la théorie des probabilités l'ont amené de mettre au point les chaînes de Markov qui l'ont rendu célèbre. Ceux-ci peuvent représenter les prémices de la théorie du calcul stochastique. [23]

III.3.1.2 Définition d'un Champ Aléatoire de Markov

Soit $X = \{X_1, X_2, \dots, X_m\}$ une famille de variables aléatoires définies sur la grille S . chaque variable X_i prend valeurs x_i dans un ensemble fini $\Omega = \{1, 2, \dots, K\}$. La famille X est appelée un champ aléatoire.

X est un champ aléatoire de Markov défini sur la grille S et relativement au système de voisinage $V(S)$ (ou un champ markovien sur un graphe $G(S, V(S))$) si et seulement si les deux conditions suivantes sont vérifiées [23]:

$$1. x \in \Omega, P(x) > 0.$$

$$2. s \in S, x \in \Omega, P(X_s = x_s / X_t = x_t, t \neq s) = P(X_s = x_s / X_t = x_t, t \in V_s(S)) \quad (\text{III.29})$$

III.3.2 principe de la segmentation markovienne

III.3.2.1 Définition d'un Champ de Gibbs

Avant de définir le champ de Gibbs (en anglais « Gibbs Random Fields »), nous devons introduire la notion de mesure de Gibbs. La mesure de Gibbs de fonction d'énergie

$U : \Omega \rightarrow \mathbb{R}$ est la probabilité P définie sur Ω par : [23]

$$P[X = x] = Z^{-1} e^{-U(x)/T} \quad (\text{III.30})$$

$$\text{avec } U(x) = \sum_{c \in C} U_{C(x)}(1e) \quad (\text{III.31})$$

C est le système de cliques associé au système de voisinage $V(s)$, T est un paramètre de contrôle appelé température et Z est une constante de normalisation appelée fonction de partition de Gibbs, elle est définie de la manière suivante : [23]

$$Z = \sum_{Y \in \Omega} e^{-U(y)/T} \quad (\text{III.32})$$

Le calcul de Z est impossible à cause du très grand nombre de configurations, par exemple dans le cas d'une image 512×512 pixels où 4 classes sont possibles, le cardinal de l'ensemble Ω

La définition du champ de Gibbs est la suivante :

« Le champ de Gibbs de potentiel associé au système de voisinage $V(s)$ est le processus aléatoire X dont la probabilité est une mesure de Gibbs associée à $V(s)$ ».

En résumé, un champ de Gibbs est déterminé par l'ensemble des potentiels $\{U_c\}$ indexés par les cliques c . [23]

III.3.2.2 Equivalence champs de Markov - champs de Gibbs

Sous les hypothèses suivantes :

- S fini ou dénombrable
- Le système de voisinage $V(S)$ est borné
- Espace des descripteurs E discret.

Le théorème d'Hammersley-Clifford établit le résultat suivant : « X est un champ de Markov relativement à $V(S)$ et $P[X=x] > 0, \forall x \in \Omega$ si et seulement si X est un champ de Gibbs de potentiel associé à $V(S)$ ». [22]

Par exemple, si nous considérons un champ de Markov de voisinage 4-connexe, nous pouvons écrire l'énergie de la configuration x sous la forme :

$$U(X) = \sum_{c=(i) \in C1} U_c(x_i) + \sum_{c=(i,j) \in C2} U_c(x_i, x_j) \quad (\text{III. 33})$$

À partir de ce théorème-là, nous pouvons donner l'expression de la probabilité de vraisemblance de l'image : [23]

$$P[X = x] = \frac{e^{-\frac{U(x)}{T}}}{\sum e^{-\frac{U(y)}{T}}} \leftarrow Z \quad \text{III. 34}$$

Avec

$$U(x) = \sum_{c \in C} U_c(x) \quad \text{III. 35}$$

Et aussi l'expression de la probabilité conditionnelle locale : [23]

$$\begin{aligned} P(X_S = x_S / X_t = x_t, t \in V_S(S)) &= P(X_S = x_S / X_t = x_t, t \in V_S(S)) \\ &= \frac{e^{-\frac{U_S(X_S=x_S / X_t=x_t, t \in V_S(S))}{T}}}{\sum_{e \in E} e^{-\frac{U_S(X_S=e / X_t=x_t, t \in V_S(S))}{T}}} \end{aligned} \quad \text{III. 36}$$

Avec :

$$U_S(x) = \sum_{c \in C/sec} U_c(x) \quad \text{III. 37}$$

III.4 Quelques MRF fondamentaux

On présente maintenant les modèles de champs de Markov les plus utilisés qui seront définis essentiellement par leur fonction de potentiel (d'énergie). [24]

III.4.1 Le modèle d'Ising

Ce modèle est le plus ancien. Il a été proposé par Ernst Ising en 1925 lors de l'étude du ferromagnétisme en physique statique. L'espace des descripteurs $E = \{-1, 1\}$ (espace binaire) et le système de voisinage peut être le 4-voisinage ou le 8-voisinage. Le potentiel des cliques $C1$ de cardinal 1 est donné par : [24]

$$U_{C1=\{s\}}(X_s) = -B \quad (\text{III. 38})$$

Tandis que le potentiel des cliques $C2$ de cardinal 2 est défini par :

$$U_{C2=\{s,t\}}(X_s, X_t) \begin{cases} = -\beta & \text{si } X_s = X_t \\ = +\beta & \text{si } X_s \neq X_t \end{cases} \quad (III. 39)$$

Avec une fonction d'énergie :

$$U(X) = - \sum_{c1=\{s\}} BX_s - \sum_{c2=\{s,t\}} \beta X_s X_t \quad (III. 40)$$

Telle que β : est le paramètre du modèle ($\beta > 0$) mesure d'interaction entre sites voisins

B:champ magnétique externe.




Figure III.5 modèle d'Ising, MRF à 2-D.

III.4.2 Le modèle de Potts

Il s'agit d'une généralisation du modèle précédent avec $K > 2$ étiquettes possibles au lieu de deux, soit $E = \{e1, e2, \dots, eK\}$. Il peut s'agir de plusieurs niveaux de gris, mais plus souvent pour ce modèle, d'étiquettes (labels) pouvant représenter une classification de l'image (par exemple les classes eau, forêt, champ, ville), et l'énergie s'écrit : [24]

$$U_{C2=\{s,t\}}(X_s, X_t) = \begin{cases} -\beta & \text{si } X_s = X_t \\ +\beta & \text{si } X_s \neq X_t \end{cases} \quad III. 41$$




Figure III.6 Exemple modèle de Potts avec différentes valeurs de β .

Ou par :

$$U_{C2=\{s,t\}}(X_s, X_t) = \beta \times (1 - 2\delta(X_s, X_t)) \quad \text{III. 42}$$

Telle que δ est le symbole de Kronecker.

L'énergie globale est donnée par : [24]

$$U(x) = \beta \sum_{C2=\{s,t\}} (1 - 2\delta(X_s, X_t)) \quad \text{(III. 43)}$$

Modèle de Potts généralisé : [25]

$$U(y) = - \sum_{C=\{s,t\}} B y_s y_t \quad \text{(III. 44)}$$

Avec B: facteur de corrélation entre sous classes.

III.7.3 Modèle Markovien Gaussien

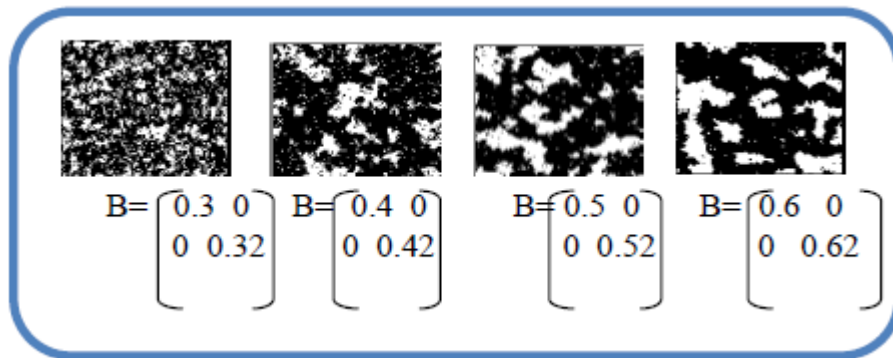


Figure III.7 Exemple modèle de Potts généralisé.

Ce modèle est réservé au champ observe (images en niveaux de gris à segmenter par exemple) et ne convient pas bien aux champs d'étiquettes. Le voisinage est 4 ou 8-connexe et l'énergie est de la forme :

$$U(x) = \beta \sum_{C2=\{s,t\}} (X_s - X_t)^2 + \alpha \sum_{s \in S} (X_s - \mu_s)^2 \quad \text{III. 45}$$

Le premier terme correspondant aux cliques d'ordre 2 est un terme de régularisation, qui favorise les faibles différences de niveaux de gris entre sites voisins pour $\beta > 0$. Le second terme peut correspondre à un terme d'attache aux données dans le cas où l'on possède une image de données échantillons. Le rapport (α/β) pondère les influences respectives de l'attache aux données et de la régularisation, et les valeurs absolues des paramètres caractère plus ou moins piqué. [24]

III.4.3 Echantillonnage de MRF

Si nous résumons les résultats précédents, la définition d'un champ de Markov passe par la définition de sa fonction d'énergie U . Celle-ci nécessite la définition d'un système de voisinage, qui définit alors le système de cliques, et de fonctions de potentiel associées aux cliques. Ces fonctions de potentiel permettent d'accéder à la probabilité globale d'une configuration, et aux probabilités conditionnelles locales.

Le problème qui se pose alors est, étant défini un champ de Markov, comment pouvons nous réaliser le tirage d'une configuration (une image ici) en suivant la loi de probabilité de Gibbs caractéristique de ce champ ? Deux algorithmes ont été proposés pour synthétiser des réalisations d'un champ de Markov qui sont :

- l'échantillonneur de Gibbs,
- l'algorithme de recuit simulé qu'on va expliquer dans la partie qui suit. [23]

III.4.3.1 L'échantillonneur de Gibbs

Cet algorithme, proposé par Geman et Geman [Geman and Geman (1984a)], repose sur la construction itérative d'une suite d'images. A la convergence, après un nombre d'itérations suffisant, les images construites sont des réalisations tirées selon la loi de Gibbs globale.

La méthode de construction de l'image à l'itération n , partant de l'image à l'itération $n-1$ se fait par mise à jour successive des sites de l'image. A l'étape n :

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

$$P(X_s = x_s | V_s) = \frac{\exp(-U_s(x_s | V_s))}{\sum_{x_s \in \Omega} \exp(-U_s(x_s | V_s))} \quad \text{III. 46}$$

- mise à jour du site s par tirage aléatoire selon la loi $P(X_s = x_s | V_s)$.

On considère que l'algorithme a convergé après un grand nombre d'itérations ou lorsque le nombre de changements est faible.[23]

III.5 Algorithme K-means

III.5.1 Définition :

L'algorithme k-means mis au point par McQueen en 1967, un des plus simples algorithmes d'apprentissage non supervisé, appelée algorithme des centres mobiles, il attribue chaque point dans un cluster dont le centre (centroïde) est le plus proche. Le centre est la moyenne de tous les points dans le cluster, ses coordonnées sont la moyenne arithmétique pour chaque dimension séparément de tous les Points dans le cluster c'est à dire chaque cluster est représentée par son centre de gravité.

III.5.2 Algorithme KMeans

Entrée

Ensemble de N données, noté par x

Nombre de groupes souhaité, noté par k

Sortie

Une partition de K groupes {C1 ,C2 ,...Ck }

Début

1) Initialisation aléatoire des centres Ck ;

Répéter

2) Affectation : générer une nouvelle partition en assignant chaque objet au groupe dont le centre est le plus proche :

$$X_i \in C_k \text{ si } \forall_j |X_i - \mu_k| = \min |X_i - \mu_j| \quad (1)$$

Avec μ_k le centre de la classe K ;

3) Représentation : Calculer les centres associe à la nouvelle partition ;

$$\mu_k = \frac{1}{N} \sum_{x \in C_k} X_i \quad (2)$$

Jusqu'à convergence de l'algorithme vers une partition stable ;

Fin.

La principale limite de cette méthode est la dépendance des résultats des valeurs de départ (centres initiaux). À chaque initialisation correspond une solution différente (optimum local) qui peut dans certain cas être très loin de la solution optimale (optimum global). Une solution naïve à ce problème consiste à lancer l'algorithme plusieurs fois avec différentes initialisations et retenir le meilleur regroupement trouvé.

L'usage de cette solution reste limité du fait de son coût et que l'on peut trouver une meilleure partition en une seule exécution [51].

III.6 Algorithme ICM (Iterated Conditional Modes)

Il s'agit d'un simulateur de Gibbs à température nulle. Les différentes étapes sont les suivantes :

- Choisir une configuration initiale λ_0 aussi proche que possible de la configuration optimale.
- Balayer l'ensemble des sites S . Chaque site s visité à l'étape n est caractérisé par son état $\lambda_s^{(n)}$ et par la configuration de son voisinage $v_s^{(n)}$. Son nouvel état $\lambda_s^{(n+1)}$ et la valeur qui correspond à l'énergie conditionnelle $U(\lambda_r^{(n)}, r \in v_s^{(n)})$ minimale.
- Poursuivre les balayages pour un nombre déterminé d'itérations ou jusqu'à la réalisation d'un critère d'arrêt.

Cet algorithme est parfaitement déterministe dans la mesure où il n'y a aucun tirage aléatoire, le seul paramètre qui influe sur le résultat final, outre le nombre de balayages, est l'ordre dans lequel on balaye l'image. D'autre part, il y a cette fois un critère d'arrêt simple qui consiste à compter le nombre de modifications d'état lors d'un balayage et à s'arrêter si ce nombre est nul ou suffisamment petit, ce qui se produit d'ailleurs en un nombre généralement faible de balayages.

Cet algorithme converge vers un minimum local de l'énergie a posteriori, cependant, le résultat obtenu dépend fortement de l'initialisation. Notons que cet algorithme ne comporte pas la caractéristique essentielle du recuit simulé qui est de visiter plusieurs puits d'énergie avant de se stabiliser dans l'un d'eux. Cet algorithme ne réalise qu'une descente dans un puits d'énergie déterminé par la configuration initiale et le mode de balayage de l'image. En ce sens, il ne peut être adapté qu'à des énergies pour lesquelles on peut disposer d'une configuration initiale convenable. Cependant ce genre d'énergies peut exister pour certains problèmes, et la sélection de telles énergies est alors une bonne solution au problème des temps de calculs. En effet, le nombre d'itérations nécessaires pour un ICM est en général très nettement inférieur à celui nécessaire pour un recuit simulé. [52]

III.7 Algorithme EM :

L'algorithme EM est un algorithme itératif très utilisé pour la recherche des paramètres au sens du maximum de vraisemblance sur des données incomplètes. L'astuce de l'EM est de ne pas maximiser la fonction de vraisemblance intractable mais une fonction plus simple définie par la densité des données complètes : $P_{Z|\Phi_y}(z|\Phi_y)$, avec $Z = (X, Y)$ (Y est la variable cachée). chaque itération de l'EM est composée de deux étapes, la première est l'étape de calcul d'espérance et la deuxième est l'étape de maximisation des données estimées. [53]

-Etape E (Estimation)

On calcule la fonction $Q(\Phi_y, \Phi_y^{[p]})$

$$Q(\Phi_y, \Phi_y^{[p]}) \triangleq E \left[\ln P_{Z|\Phi_y}(z|\Phi_y) \mid y, \Phi_y^{[p]} \right] \quad \text{III. 47}$$

-Etape M (Maximisation)

On détermine $Q^{[p+1]}$ qui maximise $Q(\Phi_y, \Phi_y^{[p]})$

$$Q^{[p+1]} = \arg \max_{\Phi} Q(\Phi_y, \Phi_y^{[p]}) \quad \text{III. 48}$$

III.8 Avantages du MRF

- coûts calculatoires plus faibles,
- information partielle sur le voisinage,
- meilleure segmentation des structures fines,
- vectorisation de l'image : parcours d'Hilbert-Peano 3D... [23]

III.9 Conclusion

Dans cette partie, on a présenté la modélisation du problème de la segmentation par les MRFs, et leurs différents modèles (modèle d'Ising, de Potts et de Gaussien), comme on a défini quelques notions telles que les champs aléatoires de Gibbs et son échantillonneur. On a vu aussi l'intérêt des champs de Markov dans l'extraction de l'information spatiale dans une image, à travers leurs voisins. Parmi les méthodes de MR

Chapitre IV

Simulations et interprétation des Résultats

IV.1 Introduction

Dans ce chapitre nous avons présenté la segmentation des images par les champs de Markov basée sur les algorithmes KMeans et EM et les résultats obtenus. Nous avons utilisé l'outil Matlab pour présenter les méthodes de segmentation par région que nous avons proposé. L'objectif de cette introduction au traitement d'images sous Matlab est de présenter la notion d'image et d'effectuer des opérations simples d'analyse d'images, Le traitement d'images est un thème de recherche situé entre l'informatique et le traitement du signal. Pour faire une comparaison objective des différentes méthodes proposées, nous proposons d'opter comme critères d'évaluations : erreur quadratique moyenne (EQM), le rapport signal sur bruit (PSNR Peak Signal to Noise Ratio), corrélation croisée normalisée (NCC), contenu structurel (SC) et erreur absolue normalisée (NAE). Nous présentons dans des tableaux les valeurs des critères de validation pour toutes les méthodes proposées. Ceci sera suivi d'une interprétation des résultats, pour pouvoir faire la comparaison entre les méthodes de segmentation utilisées. Premièrement on définit les critères d'évaluation que nous avons cité précédemment.

IV.2 Rappels sous Matlab :

Une image Matlab est une matrice bidimensionnelle de valeurs entières ou réelles. Les principales fonctions de traitement d'images sous Matlab se trouvent dans la boîte à outils (toolbox) image processing (traitement d'images). L'aide sur cette boîte à outils est obtenue en tapant `help images` en ligne de commande de Matlab. Ensuite, l'aide sur une commande particulière est obtenue en tapant `help` suivi du nom de la commande, par exemple `help imread`. Comme on peut le constater, la boîte à outils images de Matlab contient de nombreuses fonctions qui permettent le développement facile et rapide d'algorithmes en fonction du problème à traiter. C'est un très bon outil pour la validation de méthodes de traitement d'images appliquées à un problème particulier [47].

IV.2.1 Lire et écrire des images sous Matlab :

Matlab est capable de lire et de décoder les fichiers images JPEG, TIFF, BMP, PNG, HDF, PCX ou XWD. Une image sous Matlab peut être représentée sous plusieurs formes, mais toujours sous forme d'une matrice. Avant de traiter une image dans Matlab, il faut la lire et décoder son format afin de la transformer en une matrice de valeurs. L'exemple ci-dessous permet de lire une image au format TIFF, de la décoder dans la variable `img` et de l'afficher à l'écran dans une figure. La commande `axis('image')` rend l'image affichée carrée pour garder les proportions. L'appel à `axis` on permet l'affichage des graduations des axes. Enfin, `colorbar` affiche la barre des couleurs de l'image. Matlab autorise l'exportation d'images sous divers formats : BMP, TIFF, EPS, PS... La commande qui permet de sauvegarder une figure est `print -FORMAT fichier`. Dans une figure et grâce à la commande `print`, on exporte le résultat dans le format JPEG avec pour nom de fichier `result .jpg`. [47]

IV.3 Mesure de la qualité :

L'objectif de cette partie est l'étude et la définition de critères d'évaluation pour quantifier la qualité des résultats de segmentation d'images. Il existe une multitude de méthodes de segmentation dont l'efficacité reste difficile à évaluer. Il semble important de pouvoir mesurer la qualité des images. Cependant, il s'agit d'un problème difficile pour lequel on ne dispose pas de solution idéale, surtout lorsqu'il n'y pas d'image de référence. Nous allons dans cette partie définir quelques métriques de bases. [10]

IV.4 Evaluation objective :

En un mot, la mesure de la qualité objective (par opposition à l'évaluation subjective de qualité par les observateurs humains) cherche à déterminer la qualité des images algorithmiquement. Le but de la recherche de l'évaluation de la qualité objective est de concevoir des algorithmes dont la prévision de la qualité est en accord avec l'évaluation subjective des observateurs humains. Les méthodes d'évaluation de la qualité d'image peuvent être classifiées dans trois larges catégories :

IV.4 .1 Les méthodes avec référence complète,

Dans lesquelles l'algorithme a un accès à une version parfaite de l'image avec lesquelles il peut comparer l'aversion dégradée. La version parfaite vient généralement d'un dispositif de haute qualité d'acquisition, après elle est dégradée par la compression et les erreurs de transmission.

IV.4 .2 Les méthodes sans référence,

Dans lesquelles l'algorithme a un accès qu'ausignal déformé et doit estimer la qualité du signal sans connaissance de laversion parfaite. Puisque les méthodes sans référence n'exigent aucuneinformation de référence, elles peuvent être employées dans n'importe quelleapplication où la mesure de qualité est exigée.

IV.4 .3 Méthodes avec référence réduites,

Dans lesquelles l'information partielleconcernant la version parfaite est disponible. Un côté canal existe par lequellquelque information concernant la référence peut être rendue disponible àl'algorithme d'évaluation de la qualité. Les algorithmes réduits de référenceemploient cette information de référence partielle pour juger la qualité dusignaldéformé.Les mesures quantitatives les plus utilisées sont : l'erreur quadratique moyenne(MSE), le rapport crête signal sur bruit (Peak Signal to Noise Ratio, PSNR), le rapportsignal sur bruit (Signal to Noise Ratio : SNR) etc.[50]

IV.5 MÉTRIQUES DE QUALITÉ D'IMAGE

Mesure de qualité d'image joue un rôle important pour le développement des algorithmes de traitement d'images et pour évaluer la performance de l'image traitée. La qualité d'image est définie comme une caractéristique d'une image qui mesure la dégradation de l'image traitée en le comparant à une image idéale. Les humains sont généralement les observateurs et les utilisateurs de la majorité des systèmes d'imagerie, par conséquent l'évaluation de la qualité de l'image par méthode subjective est considérée comme la méthode fiable. Les applications temporelles, l'utilisation de la méthode subjective est limitée en raison de sa complexité et de sa difficulté de mise en œuvre. Par conséquent, les méthodes objectives sont plus largement utilisées pour l'évaluation de la qualité de l'image ces dernières années. Dans ce travail, nous considérons plusieurs mesures de qualité d'image et analysons leur comportement statistique pour huit mesures ciblées de la méthode SFF. [48]

IV.5.1 Erreur quadratique moyenne (MSE)

L'image dégradée \hat{I} est toujours comparée à l'originale I pour déterminer sonrapport de ressemblance. Ce critère est le plus utilisé. Il est basé sur la mesure del'erreur quadratique moyenne (MSE) calculée entre les pixels originaux et dégradés :

$$MSE = \frac{1}{M * N} \sum_{m=1}^M \sum_{n=1}^N \left(I(m, n) - \hat{I}(m, n) \right)^2 \quad (\text{IV. 1})$$

Où $(M \times N)$ est la taille de l'image, et $I p$ et $\hat{I} p$ sont respectivement les amplitudes despixels sur les images originale et dégradée. Il est vraisemblable que l'œil

tiennet beaucoup plus compte des erreurs à grandes amplitudes, ce qui favorise la mesure quadratique. [50]

IV.5.2 Le rapport signal sur bruit crête (PSNR)

L'opérateur PSNR mesure le rapport entre l'information et le bruit dans une image. Il est calculé à partir d'une image initiale img_E qui comporte l'image et le bruit et d'une image img_S qui est la version segmentée de l'image initiale img_E . Les images img_E et img_S doivent avoir la même dimension et le même type. Le PSNR s'agit de quantifier la performance des algorithmes en mesurant la qualité de réinsertion de l'image segmentée par rapport à l'image originale.

Le PSNR est défini par :

$$PSNR = 10 \log_{10} \frac{d^2}{EQM} \quad (\text{IV. 2})$$

- d est la dynamique de l'image. Dans le cas standard d'une image où les composantes d'un pixel sont codées sur 8 bits, $d = 255$.

- EQM est l'erreur quadratique moyenne et est définie pour 2 images image E et image S de taille $M \times N$.

Maximiser le PSNR revient à minimiser l'erreur quadratique. Les valeurs typiques de PSNR pour des images de bonne qualité varient entre 30 et 40 dB. [49]

IV.5.3 Contenu structurel :

Cette métrique de qualité s'exprime comme suit :

$$SC = \frac{\sum_{i=1}^m \sum_{j=1}^n (A_{ij})^2}{\sum_{i=1}^m \sum_{j=1}^n (B_{ij})^2} \quad (\text{IV. 3})$$

Une valeur plus élevée de SC (Structural Content) montre que l'image est de mauvaise qualité. [48]

IV.5.4 Corrélation croisée normalisée :

La mesure NCC (Normalized Cross Correlation) montre la comparaison de l'image traitée et de l'image de référence. NCC est exprimé comme suit : [48]

$$NCC = \sum_{i=1}^m \sum_{j=1}^n \frac{(A_{ij} \times B_{ij})}{A^2_{ij}} \quad (\text{IV. 4})$$

IV.5.5 Différence maximale :

MD (Différence maximale) fournit le maximum de signal d'erreur (c'est-à-dire différence entre l'image de référence). MD est défini comme suit

$$MD = \text{Max}(|A_{ij} - B_{ij}|) \quad (\text{IV. 5})$$

$$i = 1,2 \dots \dots m , j = 1,2 \dots \dots n$$

Plus la valeur de la différence maximale est élevée, implique la mauvaise qualité de l'image. [48]

IV.5.6 Erreur absolue normalisée :

Cette mesure de qualité peut être exprimée comme suit.

$$NAE = \frac{\sum_{i=1}^m \sum_{j=1}^n (|A_{ij} - B_{ij}|)}{\sum_{i=1}^m \sum_{j=1}^n A_{ij}} \quad (\text{IV. 6})$$

Une valeur NAE plus élevée montre que l'image est de mauvaise qualité. [48]

IV.6 Résultats de simulation

IV.6.1 Segmentation des images synthétiques :

Dans cette partie nous avons commencé à appliquer les deux méthodes de segmentation sur les images synthétiques et après nous avons évalué ces méthodes par des critères d'évaluations que nous avons vu précédemment.




Figure IV.1 a) Image originale, b) Segmentation par MRF basée K-Means, c) Segmentation par MRF basée EM

A partir des valeurs dans le tableau (Tableau IV.1) (PSNR =21.5514) et (SC= 170.5034) on peut constater que la qualité de l'image segmentée est mauvaise par la méthode ICM basé sur l'algorithme EM par rapport ICM basé sur l'algorithme KMeans pour les images synthétiques. Une valeur de PSNR infini correspond à une image non dégradée. Et cette valeur décroît en fonction de la dégradation du PSNR relie donc avec MSE l'énergie maximale de l'image. Quelle que soit la valeur de MSE, la valeur de PSNR est grande.

Critères\ Algorithmes	MSE	PSNR	NCC	SC	NAE
KMeans	2.4853e+004	4.1770	0.0132	5.6493e+003	0.9866
EM	2.5019e+004	4.1482	0.0099	5.3427e+003	0.9862
KMeans	454.9593	21.5511	0.0695	170.5034	0.9468
EM	454.9253	21.5514	0.0696	169.8783	0.9466

Tableau IV.1 Valeurs des critères d'évaluation des résultats de segmentation.

IV.7 Segmentation des images réelles :

IV.7.1 Segmentation d'image N01



a) Image originale

b) MRF basée
KMeans

c) MRF basée EM

Figure IV.2 a) Image original, b) Segmentation par MRF base KMeans, c) MRF base EM


Dans cette partie nous avons commencé à appliquer les deux méthodes de segmentation sur les images réelles et images synthétiques et après nous avons évalué ces méthodes par des critères d'évaluations que nous avons vu précédemment les résultats obtenus dans le tableau qui démontre que l'algorithme ICM basé sur la méthode EM est meilleure par rapport ICM basé sur la méthode pour KMeans les images réelles.

Critères\ Algorithmes	K-Means	EM
MSE	2.9142e+003	2.8690e+003
PSNR	13.4856	13.5535
NCC	0.0247	0.0321
SC	809.7124	753.9953
MD	253	252
NAE	0.9558	0.9532

Tableau IV.2 Valeurs de 6 critères d'évaluation des résultats de segmentation 1.

Pour pouvoir profiter des avantages des deux méthodes présentées dans le chapitre précédent, on a décidé de les utiliser pour segmenter les images. Et on a fait un tableau pour chaque un résultat, ce tableau présente les valeurs de quelques critères d'évaluation sur les résultats de segmentation. Les deux valeurs optimales (compte tenu du sens de variation des critères). Nous pouvons observer dans la figure (IV.2) l'intérêt de la segmentation par la méthode de KMeans elle permet de conserver des frontières précises. L'image de contours comme apparaît est une image typique pour ce genre de segmentation avec des EM semblables. Les valeurs de KMeans est grande par rapport la valeur de EM. Alors la qualité est bonne et le meilleur algorithme EM.

IV.7.2 Segmentation d'image N02 :



a) Image originale

b) MRF basée K-Means

c) MRF basée EM

Figure IV.3 a) Image original, Segmentation par b) MRF base K-Means, c) MRF base EM

Les résultats obtenus présentés dans les figures précédentes à partir les critères d'évaluation de segmentation sont présentés dans le tableau suivant : On peut conclure que l'algorithme ICM basé sur la méthode EM est meilleure par rapport ICM basé sur la méthode pour KMeans les images réelles.

Critères	K-means.	EM
MSE	4.8045e+003	4.7178e+003
PSNR	11.3143	11.3934
NCC	0.0112	0.0196
SC	683.0782	1.8686e+003
MD	254	252
NAE	0.9492	0.9678

Tableau IV.3 Valeurs de 6 critères d'évaluation des résultats de segmentation 2.

Les valeurs des critères donnent l'information que l'algorithme EM est meilleur que l'algorithme KMeans.

IV.8 Conclusion

Dans ce chapitre, nous avons présenté les résultats de l'algorithme de segmentation par région basée sur les champs de Markov, le travail est appliqué sur des images synthétiques et réelles, après nous avons effectué une étude comparative entre la méthode MRF basée sur KMeans et MRF basée sur EM pour évaluer ces résultats nous avons utilisé les critères suivants : MSE, PNSR, NCC, SC, MD et NAE et deux algorithmes : KMeans et EM. Les résultats obtenus montrent que la méthode MRF basée sur EM est meilleure que celle basée sur KMeans.

Conclusion générale

La segmentation d'images est une étape cruciale dans tout processus d'analyse d'images. Elle consiste à préparer l'image afin de la rendre plus exploitable par un processus automatique telle que l'interprétation. Il existe deux grandes approches purement locales. L'approche contour consiste à localiser les frontières des régions, elle est basée sur la notion de dissimilarité. Parmi ces point fort : sa simplicité et sa rapidité mais elle donne parfois des contours ouverts. L'approche région consiste à réunir les pixels connexes dans une région homogène, elle est basée sur la notion de similarité. Elle est simple et rapide mais l'utilisation uniquement des informations locales donne parfois de mauvais résultats (sous-segmentation, sur-segmentation). La coopération de ces deux approches qui sont par nature dual améliore le résultat de segmentation.

Dans ce mémoire, on a présenté différentes approches de segmentation par coopération régions-contours. Qu'elle soit séquentielle, ou bien mutuelle, la segmentation coopérative intègre les deux types d'information (régions et contours) afin de permettre une meilleure prise en compte des caractéristiques des objets de l'image. Les zones homogènes, ainsi que les transitions entre elles, sont respectées simultanément. En comparaison avec une segmentation par régions ou par contours, le résultat de la segmentation coopérative est plus fidèle à la réalité de l'image.


Ce travail décrit la classification non supervisée des images dans le cadre des modèles de Markov cachés et l'estimation. Les champs de Markov cachés sont fréquemment employés pour imposer des contraintes de régularité spatiales dans l'estimation de paramètre et les étapes de classification. Cette approche produit des résultats excellents dans de nombreux cas, mais nos expériences indiquent que l'estimation du paramètre de régularité est un problème délicat. Le temps considérable de calcul est un autre inconvénient. Les méthodes basées sur les chaînes de Markov cachées, appliquées au parcours de Hilbert-Peano de l'image, constituent une alternative intéressante. L'estimation des paramètres de régularité, qui représentent les éléments d'une matrice de transition, semble être beaucoup plus robuste. Les frontières de région sont souvent légèrement irrégulières avec cette approche, mais des structures excellentes sont généralement mieux préservées que pour le cas des champs de Markov cachés. En

plus de l'estimation robuste des paramètres de régularité, la vitesse de calcul est l'avantage principal de l'approche des chaînes de Markov cachées.

Dans nos expériences c'était environ 25 fois plus rapide que le programme basé sur les champs de Markov cachés. Plusieurs faits ressort de cette étude expérimentale. D'abord, l'intérêt de la prise en compte de l'information spatiale pour la classification des pixels d'une image apparaît de manière évidente dans les différents exemples traités. Comme il fallait s'y attendre, le choix d'un modèle de mélange gaussien conduit à des segmentations acceptables et l'on observe une nette amélioration au niveau de l'homogénéité de la segmentation avec un modèle spatial. Ce résultat est satisfaisant car cela confirme, dans le cas du champ, et montre, dans le cas des chaînes, que les approximations d'un modèle de Markov caché utilisent préservent l'information markovienne.

Dans ce mémoire, nous avons présenté les résultats de l'algorithme de segmentation par région basée sur les champs de Markov. Le travail est appliqué sur des images synthétiques et réelles, après nous avons effectué une étude comparative entre la méthode MRF basée sur KMeans et MRF basée sur EM pour évaluer ces résultats nous avons utilisé les critères suivants : MSE, PNSR, NCC, SC, MD et NAEt deux algorithmes : KMeanS et EM. Les résultats obtenus montrent que la méthode MRF basée sur EM est meilleur que celle basée sur KMeans.

Bibliographie



Bibliographie

- [1] Mesures statistiques non-paramétriques pour la segmentation d'images et de vidéos et minimisation par contours actifs. Ariane HERBULOT- Equipe d'accueil : CReATIVE-Laboratoire I3S - Université de Nice Sophia-Antipolis, CNRS.
- [2] M Sandeli, traitement d'images par des approches bio-inspirées application à la segmentation d'images, université constantine 2. 2014.
- [3] A.Medjaoui, f.fares, segmentation des images par contours actifs : application sur les Images Satellitaires à Haute Résolutions, Université Abou BakrBelkaid– tlemcen.2012
- [4] S1 :
<http://www.map.toulouse.archi.fr/works/panoformation/imagenum/imagenum.htm>
- [5] C.Houassine, segmentation d'images par une approche biomimétique hybride. Université m'hamedbougara- boumerdes. 2012.
- [6] T.Mohamed, D.Djafar, la découverte des concepts sémantiques cachés avec plusieurs niveaux d'abstraction pour la recherche d'images, universitekasdimerbah ouargla.2013
- [7] N MERABET, M MAHLIA, recherche d'images par le contenu, université abou bakrbelkaid– tlemcen.2011.
- [8] M .T.Chikh, amélioration des images par un modèle de réseau de neurones (comparaison avec les filtres de base), université abou-bakrbelkaid tlemcen.2011
- [10] GUESMIA Hamza, ALGORITHME DE SEGMENTATION PAR CHAN-VESE POUR LES DIFFERENTES MODALITES DES IMAGES , , université mohamedboudiaf –Msila 2019
- [11] M.CHETTAT, N. BELLAOUI "Etude de contours haute- échelle pour la segmentation et la fermeture de contours en présence de zones texturées et/ou bruitées".Thèse d'ingénieur, Institut d'électronique université de SAAD DAHLEB, BLIDA.2004.
- [12] K. Aounallah, les approches de segmentation d'image par coopération régions-contours, 2010.
- [13] Segmentation d'images médicales par champs aléatoire de Markov cachés, Melle Zdira Meriem, Dr.Houari Kamel, Université Larbi Ben M'hidi -Oum El Bouaghi 2010
- [14] M. Melliani, segmentation d'image par cooperationregions-contours, magistère en informatique, ecole national supérieur d'informatique, 2012.

- [15] S.Belarouci, S.Benmokhtar, méthode coopérative pour la segmentation d'images IRM cérébrales basée sur les techniques FCM et level Set., 2012
- [16] J. Canny, A, computational approach to edge detection, IEEE trans. on pattern analysis and machine intelligence, vol. 8, n°6, pp. 679-698, novembre 1986.
- [17] R. Deriche, Using Canny's criteria to derive a recursively implemented optimal edge detector, international journal of computer vision, pp. 167-187, 1987.
- [18] M. Kass, A. Witkin and D. Terzopoulos, snakes: active contour models, Cinternational journal of computer vision, 1(4): pp321–331, 1987.
- [19] SEGMENTATION NON-SUPERVISEE D'IMAGES BASEE SUR LES MODELES DE MARKOV CACHES , N. RECHID, A. KHELIFA, A. TOUMI, A. TALEB-AHMED, M. MIMI & K. BENMAHAMMED, (University Mohamed KhidherBiskra ,2011
- [20] R. Fjortoft and al, "Unsupervised classification of radar images based on hidden Markov models and generalised mixture estimation," in Conf. On SAR Image Analysis, Modelling, and Techniques, Barcelona, Spain, 25-29 September 2000, vol. SPIE 4173.
- [21] CHAMPS DE MARKOV EN TRAITEMENT D'IMAGE -- Module C3M Marc SIGELLE et Florence TUPIN - Département Traitement de Signal et des Images, Année 1999
- [22] V. Barra, « Modélisation Markovienne en imagerie », Institut Supérieur d'informatique, de Modélisation et de leurs Applications, Campus des Cézeaux – B.P. 1025 – 63173 AUBIERE CEDEX, Master MSI, 2006.
- [23] Z. Li Stan, « Markov Random Field Modeling in Image Analysis Third Edition », Springer-Verlag London Limited, 2009, pages.21-29, pages. 247-249.
- [24] Définition et simulation d'un champ de Markov Chapitre rédigé par Florence TUPIN et Marc SIGELLE.
- [25] Champs de Markov couple pour la segmentation d'images texturés - Juliette Blanchet INRIA Rhône-Alpes Equipes Mistis et Lear-Page 8.
- [26] LAKHDARI, M. Segmentation d'images par contour actif en appliquant les algorithmes génétique , mémoire d'ingénieur Institut National de formation en Informatique(INI), pp. 18 -20, 2007.

- [27] **KEFFACHE, M.AND SLIMANE, S.** Segmentation d'image médicale avec contours actifs , Mémoire d'ingénieur, Institut National de formation en Informatique (INI), pp. 11-12, 2001.
- [28] Encyclopédie Microsoft® Encarta® 2002. © 1993-2001 Microsoft Corporation, Cd-Rom.
- [29] M. Benmohammed , Présenté par Chérif TAOUCHE , Implémentation d'un Environnement Parallèle pour la Compression d'Images à l'aide des Fractales , Université Mentouri Constantine,2005
- [30] C. Diltsm, Numérisez vos collections, RCIP Octobre 2001.
http://www.chin.gc.ca/Francais/Contenu_Numerique/Guide_Gestionnaires/
- [31] **ROUSSELLE, J.J.** Les Contours Actifs : Une méthode de segmentation, Application a l'imagerie médicale, thèse de doctorat, Université François Rabelais de Tours, pp. 18, 2003.
- [32] REFICE Ismail, Mr.L.Lahouaoui, CRITÈRES D'EVALUATION POUR LES MÉTHODES DE SEGMENTATION D'IMAGES, université mohamedboudiaf – Msila,2012, *page 14*
- [33] **Chen-Chan, J.K. AggarwalChu.** The integration of image segmentation maps using region and edge information. IEEE Transactions on Pattern Analysis and Machine Intelligence, vol. 15, n° 12, pp. 1241-1252. 1993.
- [34] KouiderTadjerouni. Cours de Télédétection ; Centre National des Technologies Spatiales, Option petites échelles 2001 / 2002
- [35] Marechal Menrt. Phoenix Publication un sujet qui Mérite Débat la ville Americaine, 2002
- [36] MEDJAOUI Amina, FARESFadia, Segmentation des Images par Contours Actifs : Application sur les Images Satellitaires à Haute Résolutions, Université Abou BakrBelkaid– Tlemcen, 2012
- [37] Bouharkat Asma, BelhaouesSarah, Détection, Segmentation et Suivi d'un individu en mouvement dans une vidéo de surveillance, Université de Guelma, 2011
- [38] H. Rami, " Contribution au développement de descripteurs LBP pour le suivi d'objet en mouvement", Thèse de doctorat en électronique à l'université Rabat, 2016.
- [39] Ch. Serief, "Extraction automatique de points d'intérêt à base de la transformée en Contourlets non sous échantillonnée pour le recalage des images", Thèse de doctorat en

Science à l'université Mentouri Constantine, 2009.

[40] Ch .Lamiche, " Fusion et fouille de données guidées par les connaissances : application à l'analyse d'image " , Thèse de doctorat en science à L'université Mohammed Khider –Biskra,

2013.

[41] S. Ouadfel, " Contributions à la Segmentation d'images basées sur la résolution Collective par colonies de fourmis artificielles ", Thèse de doctorat en informatique à L'université Hadj Lakhdar de Batna, 2006.

[42] : R. Zennouhi, " Contribution à la segmentation des images couleurs par classification des pixels dans l'espace HSV et application de l'imagerie pour la détection du stress hydrique Chez *Menthaspicata L*", Thèse de doctorat en électronique à L'université de Rabat, 2013.

[43] A. Trémiau & P. Colantoni, "Regions adjacency graph applied to color image Segmentation". IEEE Transactions on Image Processing, Vol, 9 N° 4, pp : 735–744, 2000.

[44] J.C. Baillie (2003). Cours de Segmentation Module D9 : traitement d'images et vision artificielle. ENSA.

[45] Belmerabet Sarra & Bardjak Nawal, Mr M. Berkane, Segmentation d'image, Université Larbi Ben M'hidi Oum El Bouaghi, 2017

[46] Ayad Sawsen, Zeddouri Hanane, Mr Bourouaieh Douadi, Recouvrement de posture 2D, Université de Guelma, Juin 2011

[47] REFICE, Ismail. CRITÈRES D'EVALUATION POUR LES MÉTHODES DE SEGMENTATION D'IMAGES. Université Mohamed Boudiaf-M'Sila, 2012.

[48] Memon, Farida, Mukhtiar Ali Unar, and Sheeraz Memon. "Image quality assessment for performance evaluation of focus measure operators." arXiv preprint arXiv: 1604.00546 (2015). BibTeX EndNote RefMan RefWorks

[49] : kharroubi mohamed amine, segmentation d'image medicale par champ de markov, Université abdelhamid ibn badis de mostganem. 2013

[50] Ahmed seghirzianou, Evaluation de la qualité d'image, Université de mentouri de constantine, 2012

[51] Oumiloud Horiya, Mokeddem Asma, Classification non supervisée : Application de k-means, Université Abou Bakr Belkaid, Tlemcen, 2014

[52] 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. ffhal-00706168f

[53] HEDJAM, Rachid. Segmentation non-supervisée d'images couleur par sur-segmentation Markovienne en régions et procédure de regroupement de régions par graphes pondérés. 2009.

