



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



## Université Amar Thelidji- Laghouat

FACULTE: DE TECHNOLOGIE  
DEPARTEMENT D'ELECTRONIQUE

### MEMOIRE DE MASTER

Réalisé par :

-Bouaicha Sara  
-Djadour Ouissam

DOMAINE : Science et Technologie

FILIERE : Télécommunication

OPTION : Systèmes de Télécommunications

### Thème

**Segmentation d'image par champ aléatoire  
de Markov**

#### Jury de soutenance :

Nom et Prénom	Grade	Qualité
Benkouider Fatiha	MCB	Encadrant
Djarfaf Fatima	PR	Président
Birane ABdelKader	MCB	Examineur

Promotion : 2021/2022

# 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 madame Fatima benkouider 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 surtout Monsieur zitouni Abdelskader 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*



# DÉDICACES

*A ma très chère mère « Saadi »*

*Quoi que je fasse ou que je dise, je ne saurai point te remercier comme il se doit .Ton affection me couvre, ta bienveillance me guide et ta présence à mes côtés a toujours été ma source de force pour affronter les différents obstacles*

*A mon très cher père « Ghazalla »*

*Tu toujours été à mes côtés pour me soutenir et m'encourager*

*Que ce travail traduit ma gratitude et mon affection*

*A mes frères: belkacem ouael, abdelghafour,*

*A mes sœurs wahiba, wafaa, houda et aicha*

*A mes sœurs en Dieu :group « M » :Mai ,Maria ,Mariem ,Fatima ,achwak ,halima, khadidja , Najat,bakhta , Safaa, Rania ,Souad ,Hassiba*

*A mon chère « Sara ».*

*A tous mes amis de promotion de 2 eme année Master system de télécommunication surtout" Ahmed chaib Que Dieu lui fasse miséricorde" et Mourad*

*A tous les membre de ma famille et toute personne qui porte le nom Djadour et Guitta*

*Je dédie ce travail à tous ceux qui ont participé à ma réussite*



*Djadour Cuissam*

# DÉDICACES

*A mes très chers parents pour leur amour inestimable,  
Leur confiance, leur soutien, leurs sacrifices et toutes les valeurs qu'ils  
ont su m'inculquer. « Salem et aicha »*

*A mes frères: Mohammed , Allal .*

*A ma sœur Fatima, Saliha, Amina, Zhour, Douaa et Israa*

*Grand-mère Fatima et Fatna*

*Grand père Ahmed et Allal*

*Mes tantes et oncles*

*mes oncles : Masoud ,Djaloul,Lakhder,Arbi et Ali*

*A tous mes amis de promotion de 2 eme année Master system de  
télécommunication surtout" Ahmed chaib Que Dieu lui fasse  
miséricorde" et Billal*

*À mon professeur dans ma carrière universitaire « Zitouni Abdelkader »*

*A mon chère « Wissam ».*

*Bouaicha Sara*



## Résumé

Dans ce travail nous présentons la méthode de segmentation des images basée sur les champs aléatoires de Markov appliquée aux images de plaies des régions cutanées qui est l'une des étapes clés du diagnostic automatique de diagnostic afin d'identifier les infections. Nous avons établi le MRF dans les zones segmentées préliminaires décrivant les bords et les régions et définissant les processus aux limites. Un post traitement final est obtenu par morphologie mathématique pour délimiter les zones. Nous avons obtenu un résultat satisfaisant avec un taux de reconnaissance moyen de 91%, un temps de calcul acceptable et surtout que la méthode est complètement automatique.

**Mots clefs:** Segmentation des images, Champs aléatoire de Markov, ICM, Gibbs, images de plaies.

---

## ملخص

في هذا العمل ، نقدم طريقة تجزئة الصور بناءً على حقول ماركوف العشوائية المطبقة على صور الجروح في الجلد والتي تعد واحدة من الخطوات الرئيسية في التشخيص التلقائي لتحديد الالتهابات. أنشأنا حقل ماركوف العشوائي في المناطق المجزأة مبدئياً حيث تصف الحواف وتحدد عمليات الحدود. يتم الحصول على المعالجة النهائية عن طريق المرفولوجيا الرياضية لتحديد المناطق. لقد حصلنا على نتيجة مرضية بمتوسط معدل التعرف 91% ، ووقت حساب مقبول وفوق كل شيء أن الطريقة تلقائية تماماً.

**الكلمات المفتاحية:** تجزئة الصورة حقل ماركوف العشوائي ، الوضع المتكرر ، جيبس ، صور الجروح.

---

## Abstract

In this work we present the image segmentation method based on Markov random fields applied to wound images of skin regions which is one of the key steps in automatic diagnostic to identify infections. We established the MRF in preliminary segmented areas describing edges and regions and defining boundary processes. A final post processing is obtained by mathematical morphology to delimit the zones. We obtained a satisfactory result with an average recognition rate of 91%, an acceptable calculation time and above all that the method is completely automatic.

**Keywords:** Image segmentation, Hidden Markov Field, ICM, Gibbs, wound images

# Liste des figures

## CHAPITRE I

<b>Figure I.1</b>	Analyse de l'image... ..	04
<b>Figure I.2</b>	Exemples d'images, (a) image en niveau de gris du cœur, (b) image en couleur...	05
<b>Figure I.3</b>	Image en niveau de gris et son histogramme.....	06
<b>Figure I.4</b>	Exemple de segmentation d'image.....	07
<b>Figure I.5</b>	Etapes de segmentation d'image.....	08
<b>Figure I.6</b>	stratégie scalaire.....	09
<b>Figure I.7</b>	Les stratégies marginales.....	09
<b>Figure I.8</b>	Les stratégies vectorielles.....	10
<b>Figure I.9</b>	Contour et ses dérivées.....	11
<b>Figure I.10</b>	Quelques modèles de contours .....	12
<b>Figure I.11</b>	Détection de contour par les différents filtres. ....	14
<b>Figure I.12</b>	Image originale (à gauche), contour détecté par le Laplacien.....	14
<b>Figure I.13</b>	Image avant et après seuillage.....	15
<b>Figure I.14</b>	Croissance progressive d'une région.....	16
<b>Figure I.15</b>	Divisions successives des blocs.....	16
<b>Figure I.16</b>	Segmentation en régions par division.....	17
<b>Figure I.17</b>	Segmentation d'une image en régions par Division-Fusion.....	18
<b>Figure I.18</b>	Méthode de segmentation par classification.....	19
<b>Figure I.19</b>	Illustration des deux types de classification.....	20
<b>Figure I.20</b>	Approche de l'apprentissage des Moyennes. ....	22
<b>Figure I.21</b>	Principe des K-plus proches voisins (KNN).....	23

## CHAPITRE II

<b>Figure II.1</b>	Contexte spatial dans les images naturel.....	26
<b>Figure II.2</b>	Un système de voisinage dans les images 2D .....	27
<b>Figure II.3</b>	Un système de voisinage dans les images 3D.....	27
<b>Figure II.4</b>	Les cliques associées aux systèmes de voisinage 2D.....	28
<b>Figure II.5</b>	Modèle d'Ising, MRF à 2-D.....	31
<b>Figure II.6</b>	Exemple modèle de Potts avec différentes valeurs de $\beta$ .....	32

## CHAPITRE III

<b>Figure III.1</b>	Exemples d'images de palis de la base de donne.....	35
<b>Figure III.2</b>	Approche morphologique du traitement d'images.....	36
<b>Figure III.3</b>	Erosion avec B carré de taille 6.....	37
<b>Figure III.4</b>	Dilatation avec B carré de taille 6.....	38
<b>Figure III.5</b>	Fermeture avec B carré de taille 6.....	38
<b>Figure III.6</b>	Ouverture avec B carré de taille 6.....	39
<b>Figure III.7</b>	Résultat de la classification par Moyennes 6 classe.....	41
<b>Figure III.8</b>	Résultat de la segmentation par la méthode proposée .....	43

# *Liste des tableaux*

---

## *CHAPITRE I*

<b>Tableau I.1</b>	Principaux masques de calcul de gradient.....	13
--------------------	-----------------------------------------------	----

## *CHAPITRE III*

<b>Tableau III.1</b>	Représentation de l'image et du temps écoulé respectif.....	42
----------------------	-------------------------------------------------------------	----

# *Liste des abréviations*

---

<b>Acronyme</b>	<b>Signification</b>
MVS	Moyenne de Vrai Semblance.
CAH	Classification Ascendante Hiérarchique
MRF	Markov Random Field

# Sommaire

<b>Remerciements</b> .....	<i>I</i>
<b>Dédicace</b> .....	<i>II</i>
<b>Résumé</b> .....	<i>IV</i>
<b>Liste des figures</b> .....	<i>V</i>
<b>Liste des tableaux</b> .....	<i>VII</i>
<b>Liste des abréviations</b> .....	<i>VIII</i>
<b>Introduction général</b> .....	<i>01</i>
<b>Chapitre I : la segmentation d'image</b>	
I.1 Introduction.....	<i>04</i>
I.2 généralité sur l'image .....	<i>05</i>
I.2.1 Définition d'image.....	<i>05</i>
I.2.2 caractéristique d'une image numérique.....	<i>05</i>
I.3 la segmentation .....	<i>06</i>
I.3.1 Définition de la segmentation.....	<i>06</i>
I.3.2 les étapes de segmentation d'image.....	<i>07</i>
I.3.3 Technique de segmentation.....	<i>08</i>
I.3.4 les stratégies de segmentation.....	<i>08</i>
I.4 les approches de segmentation.....	<i>10</i>
I.4.1 Approches Contours.....	<i>11</i>
I.4.1.1 Méthodes dérivatives.....	<i>11</i>
I.4.2 méthode de segmentation par Approche région.....	<i>14</i>
I.4.2.1 suillage .....	<i>15</i>
I.4.2.2 Croissance de région.....	<i>15</i>
I.4.2.3 Approche division (Split).....	<i>16</i>
I.4.2.4 Approche par fusion (Merge).....	<i>17</i>
I.4.2.5 Approche par division-fusion (Split & Merge).....	<i>18</i>
I.4.3 Segmentation par classification .....	<i>19</i>
I.5 Classification des images .....	<i>21</i>
I.5.1 Nuées dynamique .....	<i>21</i>
I.5.2 la méthode de K-mean.....	<i>21</i>
I.5.3 Classificateur KPP.....	<i>22</i>
I.5.4 Classification floue .....	<i>23</i>
I.5.5 les machine à vecteurs supports(SVM).....	<i>24</i>
I.6 Conclusion.....	<i>25</i>
<b>Chapitre II . Chaines de Markov cachée</b>	
II.1 Introduction .....	<i>26</i>
II.2 Description de l'image .....	<i>26</i>
II.2.1 Système de voisinage (Neighborhood system).....	<i>26</i>
II.2.2 Notion de clique.....	<i>27</i>
II.3 Champs de Markov et champs de Gibbs.....	<i>29</i>
II.3. 1 Les Champs aléatoires de Markov en Analyse d'Images.....	<i>29</i>

II.3.2 Définition d'un Champ Aléatoire de Markov.....	29
II.3.3 principe de la segmentation markovienne.....	29
II.3.3.1 Définition d'un Champ de Gibbs.....	29
II.3.3.2 Equivalence champs de Markov - champs de Gibbs .....	30
II.3.3.3 Quelques MRF fondamentaux.....	30
II.3.3.4 Echantillonnage de MRF.....	32
II.3.3.4.1 L'échantillonneur de Gibbs.....	32
II.3.3.4.2 Algorithme ICM (IteratedConditional Modes).....	33
II.3.3.5 Avantages du MRF .....	33
II.4 . Conclusion.....	33
<b>Chapitre III : Résultat et Discussion</b>	
III.1 Introduction.....	35
III.2 Les images .....	35
III.3 morphologie mathématique.....	35
III.3.1 Notion d'élément structura.....	36
III.3.1.1 L'érosion.....	37
III.3.1.2 La dilatation.....	37
III.3.1.3 Fermeture.....	38
III.3.1.4 Ouverture.....	38
III.3.1.5 Les filtres alternés séquentiels.....	39
III.4 Méthode.....	39
III.5 Résultats et discussion.....	41
III.5.1 Résultats de la Segmentation .....	41
III.6 Conclusion.....	43
<b>Conclusion générale</b> .....	45
<b>Références bibliographiques</b> .....	47

*Introduction*  
*générale*

# Introduction général

---

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 [1].

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 [2].

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 [3]. 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 dans les champs de Markov pour segmenter en régions distinctes d'une image [4]. 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-moyennes. Le formalisme des champs de Markov nous permet d'obtenir des classifications plus régulières en favorisant une régularité entre les pixels voisins [5,6]. 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 [9]. Nous proposons dans ce mémoire une méthode de segmentation basées sur les champs de Markov cachée appliquées aux images médicales plus particulièrement la segmentation l'image de la plaie de la région cutanée qui est l'une des étapes clés du diagnostic automatique qui peut aider le médecin afin d'identifier les infections. Ce mémoire s'articule autour de trois chapitres qui nous permettront de présenter les différents aspects de notre travail.

# Introduction général

---

Le mémoire est axé sur trois chapitres outre l'introduction générale et la conclusion générale.

Le premier chapitre présente les méthodes de segmentation et de classification Le deuxième chapitre est consacré à la notion des champs aléatoire de Markov Le chapitre trois présente la méthode de morphologie mathématique et les discussions des résultats.


*Chapitre I*

*Les segmentation*  
*d'image*

## I. 1 Introduction

Le processus d'analyse d'image doit être défini comme l'ensemble des méthodes et outil permettant de décrire quantitativement le contenu d'une image. La segmentation d'image est une étape critique et importante dans l'analyse d'image ; Par conséquent, une bonne segmentation d'image conduit à une bonne analyse d'image où des mesures sont prises à partir de l'image segmentée pour extraire des paramètres discriminants de classification ou d'interprétation. L'objectif de la segmentation est de fournir une représentation concise et représentative de leur contenu informationnel plus utile que leur score total [9]. Il s'agit d'extraire des indicateurs visuels (primitifs) suffisamment pertinents pour les entités qui composent la scène où l'image est prise [10]. Les indicateurs visuels peuvent être définis comme des informations visibles directement à partir de la perception de l'image (contours, zones). En analyse d'images les étapes suivantes sont souvent réalisées (figure 1.1):

- Acquisition des données
- Prétraitement
- Segmentation
- Interprétation




**Figure I.1** Analyse de l'image

Les chercheurs ont développé une grande variété de méthodes de segmentation ; Il est difficile de déterminer si une méthode est meilleure que l'autre car cela dépend du domaine d'application. Dans ce chapitre, nous passerons en revue les nombreux types de méthodes de hachage et l'idée principale derrière chacune [11].

## I.2 Généralités sur l'image

### I.2.1 Définition de l'image

Une image est une représentation du monde. En traitement d'image, la majorité du temps, on considère qu'il s'agit d'une fonction mathématique de  $R \times R$  dans  $R$  où le couplet d'entrée est considéré comme une position spatiale, le singleton de sortie comme l'intensité (couleur ou niveaux de gris) du phénomène physique. Il existe deux types d'images: image en niveau de gris dont les pixels sont codés de  $[1..255]$  et les images en couleurs qui sont formées par trois images en composition (rouge, bleu et vert), figure I.2.



(a)



(b)


**Figure I.2** Exemples d'images, (a) image en niveau de gris du cœur, (b) image en couleur

### I.2.2 Caractéristiques d'une image numérique

L'image est un ensemble structuré d'informations caractérisé par les paramètres suivants [12]:

- **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 ( $n$ ) de cette matrice multiplié par le nombre de colonnes ( $m$ ) nous donne le nombre total de pixels dans une image.
- **Résolution :** C'est la clarté ou la finesse de détails atteinte par un moniteur ou une imprimante dans la production d'images. Sur les moniteurs d'ordinateurs, la résolution est exprimée en nombre de pixels par unité de mesure (pouce ou centimètre). On utilise aussi le mot résolution pour désigner le nombre total de pixels affichables horizontalement ou verticalement sur un moniteur; plus grand est ce nombre, meilleure est la résolution.

- **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.
- **Histogramme**: L'histogramme des niveaux de gris ou des couleurs d'une image est une fonction qui donne la fréquence d'apparition de chaque niveau de gris (couleur) dans l'image. Il permet de donner un grand nombre d'information sur la distribution des niveaux de gris (couleur) et de voir entre quelles bornes est répartie la majorité des niveaux de gris (couleur) dans le cas d'une image trop claire ou d'une image trop foncée, figure I.3.



**Figure I.3** Image en niveau de gris et son histogramme


## I.3 La segmentation

### I.3.1 Définition de la segmentation

La segmentation d'image est un type de traitement d'image qui vise à regrouper des pixels selon des critères prédéfinis. Les pixels sont ensuite regroupés en régions homogènes (lissage de texture, lissage de niveau de gris, lissage de couleur, etc.) qui constituent une section de l'image.

Le partitionnement est une décomposition mathématique de l'image  $I$  en  $N$  régions  $R_i$ . Toute la région  $R_1, R_2, \dots, R_N$  est un hachage d'image [9], telle que:

- i.  $\bigcup_{i=1}^N R_i = I$  ;
- ii.  $\forall (i, j), i \neq j, R_i \cap R_j = \emptyset$ .
- iii.  $\forall R_i, P(R) = \text{vrais}$ .
- ii.  $\forall (i, j), R_i$  spatialement adjacents à  $R_j$   $P(R_i \cup R_j) = \text{faux}$



**Figure I.4** Exemple de segmentation d'image

La première condition est que la combinaison de toutes les régions donne l'image d'origine et que chaque pixel de l'image doit appartenir à l'une des régions. La deuxième exigence stipule qu'un pixel ne peut pas se trouver dans deux régions différentes en même temps. La troisième exigence dicte que chaque région adhère au prédicat d'uniformité mentionné dans P. Le quatrième critère implique le non-respect de ce même prédicat pour la rencontre de deux régions voisines.

Le processus de segmentation produit une image dans laquelle une forme est attribuée à chaque pixel [13]. L'objectif de la segmentation se résume aux points suivants:

- Fournir des régions homogènes (sur la base d'un ensemble de critères).
- Marquez les zones avec précision.
- Étude et interprétation des structures anatomiques.
- Réduction de bruit.

### **I.3.2 Les étapes d'un processus de segmentation d'images**

Les différentes étapes permettant la segmentation d'une image sont résumées dans la Figure I.5, remplace :

- 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

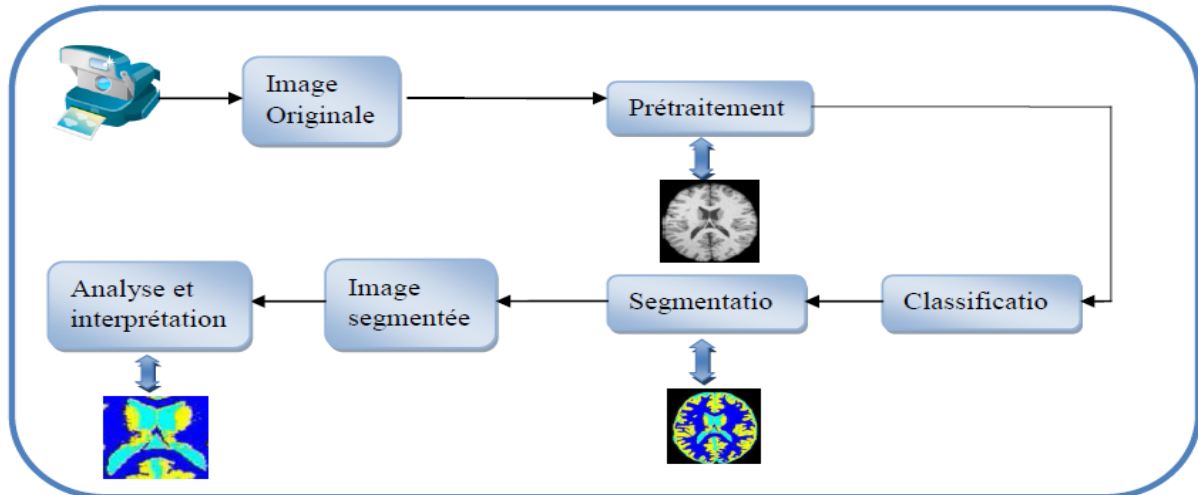


Figure I.5 les Etapes d'un processus de segmentation d'images.

### I.3.3 Techniques de segmentation

Deux principales méthodes de segmentation d'image peuvent être distinguées :

- i) *Approche contour* : segmentation basée sur l'extraction des contours de l'objet image.
- ii) *Approche région* : segmentation basée sur l'extraction de régions homogènes de l'image.

Ces deux approches complémentaires peuvent être divisées en quatre catégories :

1. Une division basée sur les régions (en anglais : division based on region). Il existe des termes tels que « croissance régionale » et « fragmentation régionale » (« fusion régionale ») (« fragmentation et fusion »).
- 2 - Segmentation basée sur l'outline (en anglais : Edge-based segmentation),
3. Segmentation basée sur la classification
4. Segmentation basée sur la classe (seuil).

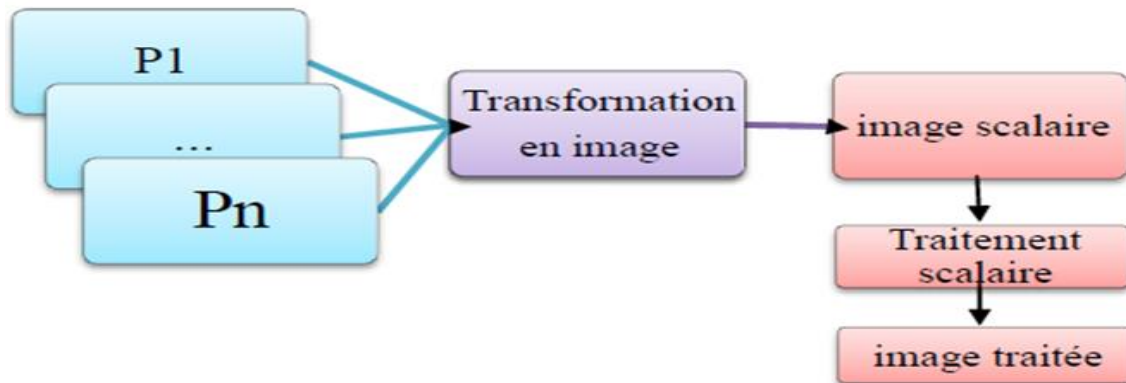
### I.3.4 Les stratégies de segmentation

En traitement d'image, il existe quatre types différents stratégies de la segmentation des Images couleur, à savoir les stratégies scalaires, marginales, vectorielles et hybrides.

#### — Les stratégies scalaires

Cette stratégie consiste de passer d'une image couleur à une image monochrome ou à niveau de gris. En effet, elle commence par une fusion, sous forme mono composante, des 3 composantes de l'image couleur (P1, P2, P3), puis traite l'image en niveaux de gris ainsi obtenue (figure I.6). Parmi les méthodes qui permettent le passage d'une image vectorielle couleur à une image scalaire, la transformation Karhunen-loève [14]. Cette

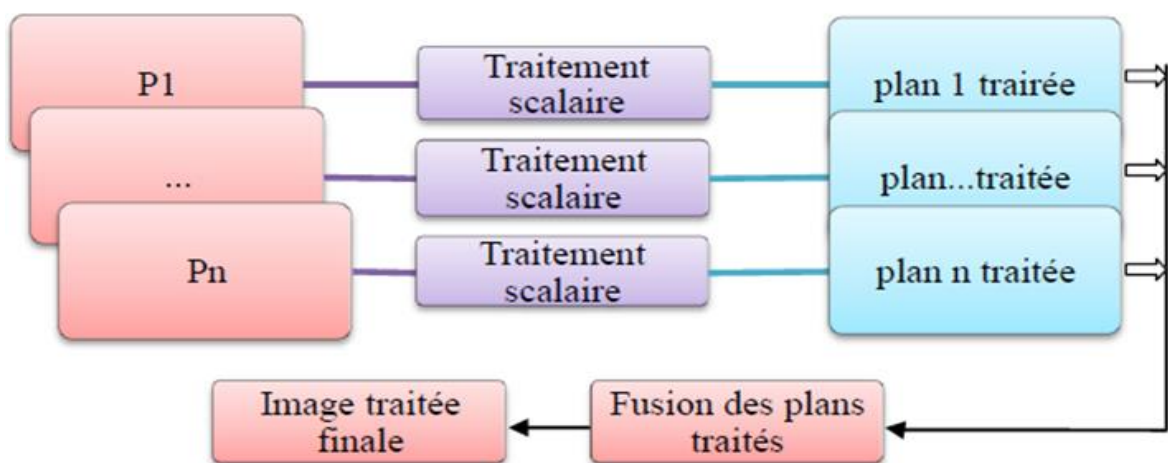
transformée basée sur le principe de l'analyse en composantes principales (ACP), dont on ne retient que la première composante.



**Figure I.6** stratégie scalaire

- *Les stratégies marginales*

Cette stratégie consiste à traiter chaque composant individuellement avec des traitements à un seul composant, ce qui est similaire à l'imagerie monochromatique. Le graphique ci-dessous (figure I.7) illustre cette stratégie qui, de par sa structure, ignore complètement toute association potentielle entre les différents composants, bloquant ainsi l'accès aux informations susceptibles d'améliorer les performances du traitement. L'avantage de cette stratégie est qu'elle n'utilise que des processeurs scalaires. Toutes les anciennes méthodes d'imagerie monochrome peuvent maintenant être utilisées directement, sans aucun changement [15].




**Figure I.7** Les stratégies marginales

– *Les stratégies vectorielles*

En raison des associations spatiales et chromatiques entre chacun des plans de l'image, il est souvent plus approprié de zoner les zones globales polies. En effet, dans l'espace colorimétrique créé par les vecteurs  $x_1$ ;  $x_2$ ;  $X_3$ , chaque pixel  $P$  est traité comme un vecteur  $P$  ( $x_1, x_2, x_3$ ). En conséquence, la division prend en compte les trois composants (figure I.8), en tenant compte de la corrélation entre eux.

La stratégie vectorielle a également l'avantage de ne nécessiter qu'un seul traitement, bien qu'elle puisse être coûteuse à long terme.



**Figure I.8** Les stratégies vectorielles

– *Les Stratégie hybride*

La stratégie hybride est le résultat de la combinaison des deux stratégies marginale et vectorielle. Il est fréquemment utilisé dans la segmentation des images couleur à l'aide de l'analyse d'histogrammes. Il s'agit d'examiner des histogrammes bidimensionnels créés en projetant un histogramme tridimensionnel sur deux des trois axes colorimétriques utilisés [15].

## I.4 Les approches de Segmentation

La segmentation d'image nécessite de diviser l'image en groupes homogènes. Les méthodes de fragmentation sont souvent divisées en deux classes.

- Approches contours
- Approches région

Les approches sont complémentaires les unes des autres et aucune n'a démontré sa supériorité sur l'autre. Chacun a son propre ensemble d'avantages et de domaines d'application

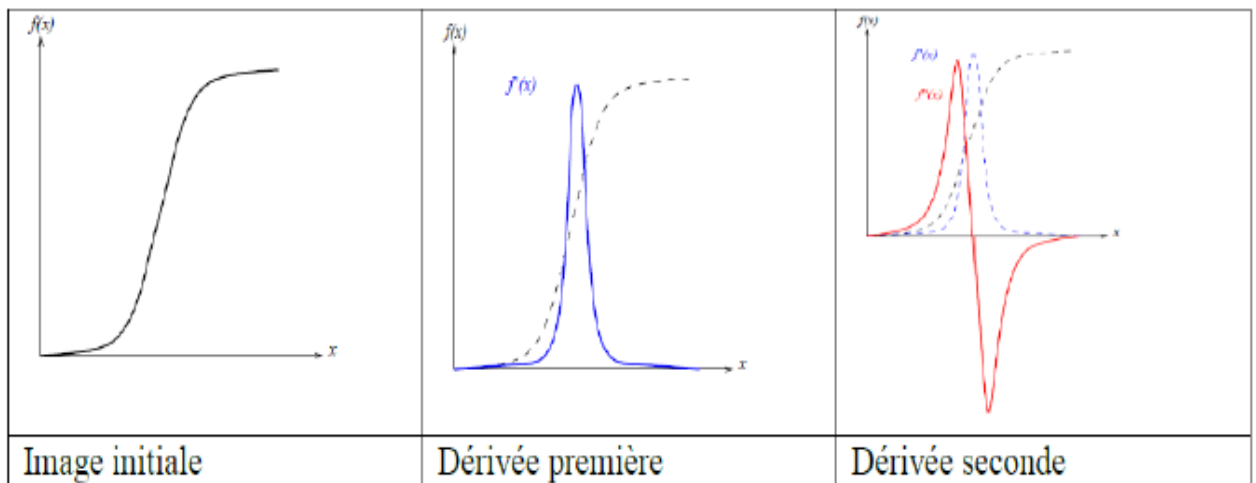
### I.4.1 Les approches de contours

L'extraction de contour a l'avantage de fournir des contours bien localisés dans la plupart des cas, et elle fonctionne bien lorsque l'une et l'autre des zones du contour ont des intensités quelque peu fluctuantes. En ce qui concerne les limites, les méthodes d'extraction des surfaces sont peu précises. Les variations (densité, couleur, texture, etc.) d'une image représentent des changements dans les propriétés physiques ou géométriques de la scène ou de l'objet vu.


Ce sont les limites des zones qui correspondent aux bords ou aux parties d'objets.

#### I.4.1.1 Méthodes dérivatives

Les méthodes dérivatives sont les plus utilisées pour détecter des transitions d'intensité par différenciation numérique (Première et deuxième dérivé), figure I.9. A chaque position, un opérateur est appliqué afin de détecter les transitions significatives au niveau de l'attribut de discontinuité choisi (figure I.10). Le résultat est une image binaire constituée de points de contours et de points non-contours.



**Figure I.9** Contour et ses dérivées



**Figure I.10** Quelques modèles de contours

De nombreuses techniques d'extraction de contours existent dans la littérature. Elles peuvent être classées comme suit [16]:

- Les algorithmes basés sur le gradient (ou opérateurs du premier ordre).
- Les algorithmes basés sur le Laplacien (ou opérateurs du second ordre).
- segmentation d'image par coopération régions-contours,

#### • *L'approche Gradient*

Les contours dans une image étant caractérisés par une forte variation de contraste. Il est évident de chercher un opérateur permettant de caractériser les zones où les niveaux de gris augmentent ou diminuent très vite. La dérivée (le gradient) répond tout à fait à ce problème. Le gradient d'une image donne les taux de changement de niveau de gris par unité de distance dans les directions des axes de coordonnées. Il est défini comme un vecteur caractérisé par son amplitude et sa direction, tels que :

- L'amplitude est liée à la quantité de variation locale des pixels.
- La direction du gradient est orthogonale à la frontière qui passe au point considéré.

Le gradient d'une image dans un point  $p(x, y)$  est le vecteur  $I(x, y)$  qui est défini par :

$$\nabla I(x, y) = \left( \frac{dI(x,y)}{dx}, \frac{dI(x,y)}{dy} \right)^2 \quad (I.1)$$

Et pour calculer ce gradient, on effectue généralement, le produit de convolution de l'image avec un opérateur de dérivation fournissant deux masques  $M_1$  et  $M_2$  tels que:

$$\frac{dI(x,y)}{dx} = M_1 \cdot f(x, y) \quad (I.2)$$

$$\frac{dI(x,y)}{dy} = M_2 \cdot f(x, y) \quad (I.3)$$

Le module  $m$  de gradient est défini par :

$$m = \sqrt{\left(\frac{dI(x,y)}{dx}\right)^2 + \left(\frac{dI(x,y)}{dy}\right)^2} \quad (I.4)$$

Plusieurs opérateurs existent on cite:

*i. 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]:

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

Avec :

$$h_j = \begin{bmatrix} 1 & 0 & -1 \\ c & 0 & -c \\ 1 & 0 & -1 \end{bmatrix} \text{ et } h_i = \begin{bmatrix} 1 & c & 1 \\ 0 & 0 & 0 \\ -1 & -c & -c \end{bmatrix} \quad (I.5)$$

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  $c=2$ .

*ii. 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" [9].

Il existe plusieurs opérations permettant l'approximation du gradient par convolution de l'image et le masque, on peut citer (tableau I.1) :

	0°	45°	90°	135°
Robert	$\begin{pmatrix} 0 & 0 & 0 \\ 0 & 1 & 0 \\ 0 & 0 & -1 \end{pmatrix}$		$\begin{pmatrix} 0 & 0 & 0 \\ 0 & 0 & 1 \\ 0 & -1 & 0 \end{pmatrix}$	
Prewit	$\begin{pmatrix} -1 & 1 & 1 \\ -1 & -2 & 1 \\ -1 & 1 & 1 \end{pmatrix}$	$\begin{pmatrix} -1 & -1 & 1 \\ -1 & -2 & 1 \\ 1 & 1 & 1 \end{pmatrix}$	$\begin{pmatrix} -1 & -1 & -1 \\ 1 & -2 & 1 \\ 1 & 1 & 1 \end{pmatrix}$	$\begin{pmatrix} 1 & 1 & 1 \\ -1 & -2 & 1 \\ -1 & -1 & 1 \end{pmatrix}$
sobel	$\begin{pmatrix} -1 & 0 & 1 \\ -2 & 0 & 2 \\ -1 & 0 & 1 \end{pmatrix}$	$\begin{pmatrix} -2 & -1 & 0 \\ -1 & 0 & 0 \\ 0 & 1 & 2 \end{pmatrix}$	$\begin{pmatrix} -1 & -2 & -1 \\ 0 & 0 & 0 \\ 1 & 2 & 1 \end{pmatrix}$	$\begin{pmatrix} 0 & 1 & 2 \\ -1 & 0 & 1 \\ -2 & -1 & 0 \end{pmatrix}$
kirsch	$\begin{pmatrix} -3 & -3 & 5 \\ -3 & 0 & 5 \\ -3 & -3 & 5 \end{pmatrix}$	$\begin{pmatrix} -3 & -3 & -3 \\ -3 & 0 & 5 \\ -3 & 5 & 5 \end{pmatrix}$	$\begin{pmatrix} -3 & -3 & -3 \\ 3 & 0 & -3 \\ 5 & 5 & 5 \end{pmatrix}$	$\begin{pmatrix} -3 & 5 & 5 \\ -3 & 0 & 5 \\ -3 & -3 & -3 \end{pmatrix}$

**Tableau I.1** Principaux masques de calcul de gradient

Cette approche permet une approximation des passages par zéro de la dérivée seconde de l'image qui détermine les transitions des intensités des pixels. La figure I.9 donne quelques exemples.



**Figure I.11** Détection de contour par les différents filtres [9]

### iii. L'approche Laplacien

L'opérateur gradient de second ordre (Laplacien) peut être calculé par convolution d'un des deux masques  $M_1$ ,  $M_2$  qui utilisent respectivement 4 et 8 voisinages connectés [17].

$$M_1 = \begin{bmatrix} 0 & -1 & 0 \\ -1 & 4 & -1 \\ 0 & -1 & 0 \end{bmatrix} \text{ et } M_2 = \begin{bmatrix} -1 & -1 & -1 \\ -1 & 8 & -1 \\ -1 & -1 & -1 \end{bmatrix}$$

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




**Figure I.12** Image originale (à gauche), contour détecté par le Laplacien.

## I.4.2 Méthodes de segmentation par approche régions

La segmentation d'images par l'approche régions consiste à découper l'image en région. Les Méthodes appartenant à cette catégorie, se basent sur la similarité entre les pixels. Pour cela il Existe différentes techniques que nous allons présenter dans ce qui suit :

### I.4.2. 1 Seuillage

C'est l'une des plus simples et plus anciennes techniques utilisées dans la segmentation d'images, qui suppose que l'image est composée de régions avec différentes gammes de niveau de gris. Une procédure qui fixe le seuil détermine une valeur d'intensité appelée seuil [18].




**Figure I.13** Image avant et après seuillage

Le seuillage d'image peut être utilisé pour créer une image comportant uniquement deux valeurs (noir ou blanc), il remplace un à un les pixels d'une image à l'aide d'une valeur fixée (seuil) exemple 123, Ainsi si un pixel a une valeur supérieure au seuil il prendra la valeur 255 (blanc), et si la valeur est inférieure il prendra la valeur 0 (noir).

Etant la méthode de segmentation la plus simple et la plus rapide, le seuillage est utilisé pour les prétraitements d'image médicale.

### I.4.2. 2 Croissance de région

Les algorithmes de croissance de régions sont fondés sur l'agrégation progressive des pixels à partir d'un point initial appelé «germe», selon un ou plusieurs critères. Les points voisins du germe sont successivement examinés; s'ils vérifient les critères d'agrégation, ils sont inclus à la région et deviennent à leur tour un germe [19]. Dans le cas contraire, ils sont rejetés comme ce que illustré dans la figure I.12.



**Figure 1.14** Croissance progressive d'une région

La segmentation par croissance de régions est simple à mettre en œuvre. L'avantage principal de cette technique réside dans la prise en compte des informations contextuelles par le mécanisme de croissance. Alors que la disposition des germes initiaux représente un inconvénient. En effet, celle-ci nécessite l'intervention d'un opérateur, en particulier lorsqu'il s'agit de détecter les tumeurs, qui, par définition, n'ont pas de localisation à priori [19].

### 1.4.2.3 Approche par division (Split)

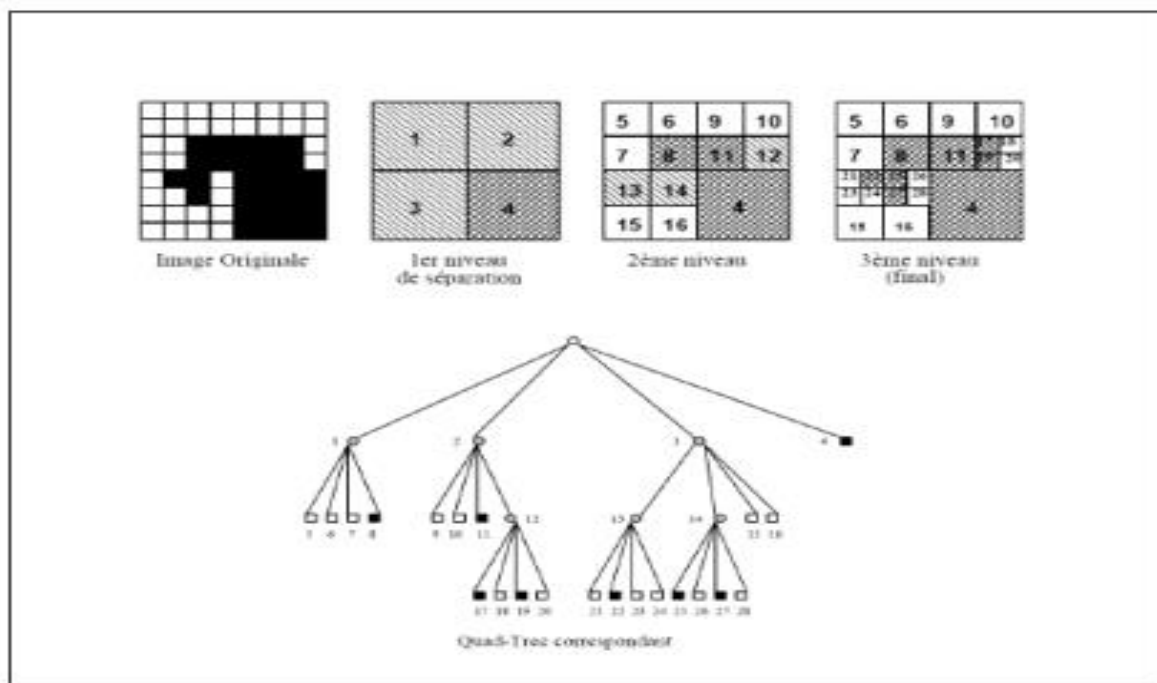
Les approches par division sont des méthodes descendantes qui consistent à tester la validité du critère de l'homogénéité de manière globale sur une large zone de l'image. Si le critère est valide l'algorithme s'arrête. Sinon on décompose la zone considérée en zones plus petites et on applique la méthode jusqu'à obtention d'une zone qui valide le critère. Ceci se traduit en pratique par une division de l'image originale en quatre. Puis à nouveau une division de chacune de ces zones en quatre, tant que le critère n'est pas vérifié, comme le montre la figure I.15 [20].



**Figure I.15** Divisions successives des blocs [20].

### *Algorithme Récursif de la segmentation en régions par division*

L'algorithme produit un arbre appelé QuadTree qui donne une structure hiérarchisée des régions qui correspondent au critère de l'homogénéité (exemple de critère d'homogénéité : même niveau de gris du voisin à 10% près). Ainsi, une région qui répond au critère forme un noeud terminal ou feuille de l'arbre, sinon elle forme un nœud d'où partent quatre branches correspondant aux quatre zones sur lesquelles on réapplique l'algorithme. La figure I.16 illustre un exemple de segmentation en région par division ainsi le QuadTree correspondant. Sur cet exemple l'image initiale a seulement deux régions, mais après l'application de l'algorithme de la division, le nombre de région est augmenté à 22. C'est ce que l'on appelle une sur-segmentation [19].



**Figure 1.16** Segmentation en régions par division

#### **I.4.2.4 Approche par fusion (Merge)**

Les approches par fusion sont des méthodes ascendantes, qui consistent à explorer l'image à partir de pixels initiaux appelés « germes ». Ces germes peuvent être sélectionnés de façon aléatoire ou automatique et faire croître ceux-ci pour former des régions connexes et homogènes. La règle de fusion de deux régions est :

- i. Les deux régions répondent de manière similaire au critère d'homogénéité.
- ii. Les deux régions sont adjacentes.

La méthode de parcours de l'image n'est pas déterminée à l'avance, et l'algorithme fait croître au maximum une région avant de passer à la suivante.

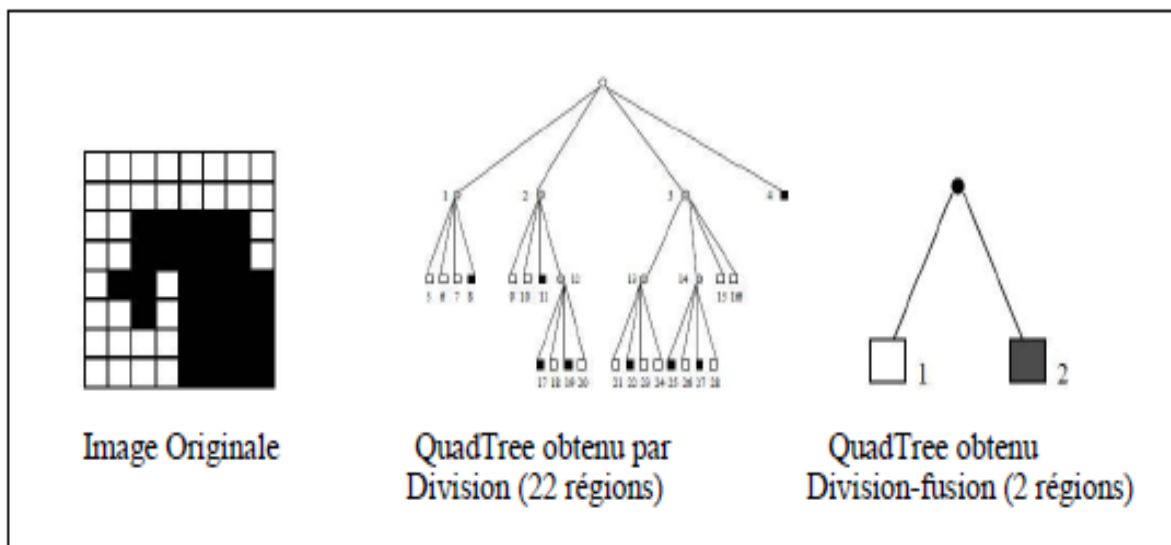
#### 1.4.2.5 Approche Division-Fusion (Split & Merge)

La méthode par division aboutie à une structure hiérarchisée permettant d'établir des relations de proximité entre les régions mais sépare une même région en sous-ensembles distincts (sur-segmentation). Quant à la méthode par fusion, elle permet d'obtenir un nombre minimal de régions connexes, mais fournit celles-ci sous une structure horizontale ne donnant pas de relations de proximité entre les régions. C'est pour cela que cette méthode qui combine les deux a été définie.

L'algorithme de cette méthode se résume comme suit :

- Appliquer la méthode de division en construisant le QuadTree dans le sens racine vers feuilles.
- Parcourir l'arbre obtenu dans le sens feuilles vers racine en fusionnant les régions similaires au sens d'un prédicat de regroupement.

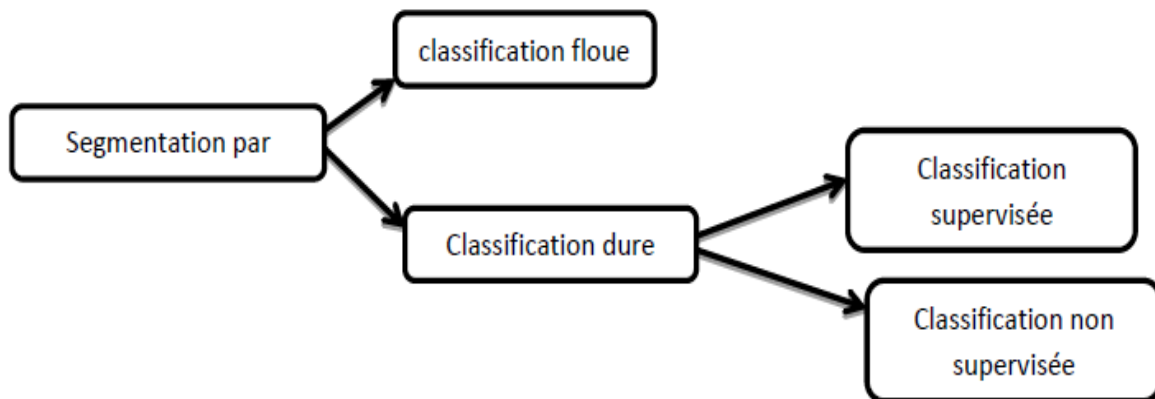
Ainsi une description structurale de l'image avec des régions connexes de taille maximale est obtenue, comme illustré dans la figure I.18 [20].



**Figure I.17** Segmentation d'une image en régions par Division-Fusion

### 1.4.3 Segmentation par classification

Elle peut être soit par classification floue ou par classification dure (figure I.19)



**Figure I.18** Méthode de segmentation par classification

Les méthodes de classification permettent de regrouper les objets en groupes ou catégories plus homogènes. Les objets d'un groupe partagent des propriétés communes; ils sont similaires mais pas identiques aux objets des autres catégories. En général, les résultats des diverses méthodes de catégorisation sont plus ou moins différents [21].

Le terme "classement" fait référence à une méthode supervisée qui consiste à définir une fonction qui attribue une ou plusieurs classes à chaque variable. Les méthodes de classification sont classées en : méthode supervisée et non supervisée, figure I.19.

#### ***Approche supervisée:***

Dans la première approche, on suppose qu'un expert a déjà fourni les étiquettes pour chaque donnée ; les étiquettes sont des classes d'appartenance. Le but de la classification supervisée (aussi appelée classification ou classification inductive) est d'apprendre par l'exemple. Elle tente d'expliquer et de prédire l'occurrence de papiers appartenant à des classifications préalablement identifiées. Il s'agit donc d'un ensemble de stratégies visant à déterminer l'appartenance d'un individu à une classe en fonction uniquement des valeurs qu'il accepte. C'est un problème de classification avec un ensemble d'apprentissage de  $N$  exemples et un ensemble de  $M$  classes :

Si  $X^i$ , ( $i = 1, \dots, N$ ) est un vecteur d'attributs d'entrée décrivant l'exemple  $i$  et  $Y^i$  sa classe, alors l'ensemble d'apprentissage complet est noté :


$$LS = (X^i, Y^i), i = 1, \dots, N \quad (I.5)$$

Il existe une variété de méthodes d'apprentissage supervisé disponibles:

- Arbre de décision.
- Méthode des k plus proches voisins.
- Réseau de neurones.
- Arbre de décision
- Support à vecteur machine

### *Approche non supervisée:*

Dans les méthodes de classification non supervisée, le traitement se fait uniquement sur les données numériques de l'image : il n'y a pas de classes définies a priori dès le départ. Une fois la segmentation effectuée, alors seulement, l'analyste cherche à interpréter, si possible de façon utile, les différentes classes trouvées. Bien sûr, l'analyste n'est pas totalement absent du processus de segmentation : il choisit certains paramètres (nombre de classes, distance entre les classes, méthode statistique...). L'interprétation des classes obtenues est souvent difficile, mais les classifications non supervisées sont idéales à titre de pré-classification ou lorsqu'on ne dispose de quasiment aucune information de terrain sur l'image. Elles proposent souvent une partition de l'image, créée à partir d'un découpage issu de l'(des) histogramme(s), mettant en évidence des noyaux auxquels on rattache les points plus éloignés grâce à un calcul de distance. Les méthodes statistiques les plus usitées en classification non supervisée sont la Classification Ascendante Hiérarchique (CAH) et la méthode des centres mobiles, méthode de moyenne de vraisemblance [12].



**Figure I.19** Illustration des deux types de classification, à gauche non supervisée, à droite supervisée

## I.5 Classification des images

Dans cette partie nous abordons quelques méthodes de classifications qui seront utilisées dans la suite du travail, et nous passons en revue de deux méthode de classification supervisée.

### I.5.1 Nuées dynamique

La méthode des nuées dynamiques consiste à trouver la partition optimale d'un ensemble d'individus en  $c$  sous-ensembles (classes), chaque sous-ensemble  $C_i$  est représenté par un noyau.

On note :

$\Omega$  est l'ensemble des partitions  $\pi$  de  $X$  en  $c$  classe  $(C_1, \dots, C_c)$ .

$V = (v_1, \dots, v_c)$  un ensemble de  $c$  noyaux, où  $v_i$  est le noyau de la classe  $C_i$ .

$F(x, v_i)$  un critère qui mesure la dissimilarités (dissemblance) entre l'individu  $x$  et la classe  $C_i$ .

La classification se fait de telle façon que la somme des mesures entre les individus et leur classe soit la plus faible possible, c'est-à-dire la partition  $\pi$  et la représentation  $v$  associée qui optimisent leur adéquation au sens du critère  $f$ . la fonction objectif à minimiser s'écrit alors [22]:

$$gf(\Omega) = \sum_{v_i \in \Omega} f(XK) \sum_{X_k \in c_i} \quad (I.6)$$

La solution optimale à un algorithme de partitionnement est de trouver, parmi les partitions possibles contenant  $c$  classes, celle qui minimise la fonction de coût. Cependant, cette option n'est pas guère envisageable d'un point de vus pratique, compte tenu de l'explosion combinatoire, même pour une population d'échantillons de taille raisonnable. Par conséquent, et en guise d'alternative, la majorité des approches utilisent une technique d'optimisation itérative.

### I.5.2 La méthode des k-means

Cette méthode a été introduite par J. McQueen en 1971 et mise en œuvre sous sa forme actuelle par E. Forgy. De nombreuses variantes se sont succédées depuis afin d'étendre ses capacités de classification (séparations non linéaires) : kernel k-means (k-means basée sur des méthodes à noyaux), améliorer ses performances : global -k-means, -Harmonicmeans, automatiser le choix du nombre de clusters : Gaussian-means, -means [23].

Dans le cadre de la classification non supervisée, on cherche généralement à partitionner l'espace en classes concentrées et isolées les unes des autres. Dans cette optique, l'algorithme des k-means vise à minimiser la variance intra-classe, qui se traduit par la minimisation de l'énergie suivante :


$$E = \sum_{c \in D} \min(x - m_c)^2 \quad (I.7)$$

avec  $C$  l'ensemble des clusters et pour chaque cluster  $c$ ,  $x$  est un élément de  $c$ ,  $m_c$  son centre (appelé noyau).

$D$  l'ensemble des données que l'on cherche à classer.

La classification k-means est une méthode itérative qui, quel que soit son point de départ, converge vers une solution. La solution obtenue n'est pas nécessairement la même quel que soit le point de départ. Pour cette raison, on répète en général plusieurs fois les calculs pour ne retenir que la solution la plus optimale pour le critère choisi. L'algorithme est le suivant:

- i. Initialiser l'ensemble des centroïdes contenant des éléments pris au hasard de l'ensemble de données, ou choisis d'après des connaissances et assigner chaque point au centroïde le plus proche.
- ii. Calculer les nouveaux centroïdes des classes construites. Les centroïdes étant les centres des classes, ils sont calculés par la moyenne des éléments de la classe.
- iii. Générer une nouvelle partition de l'ensemble de données en assignant chaque point au centroïde le plus proche.
- iv. S'il y a changement dans la partition réitérer depuis l'étape ii.



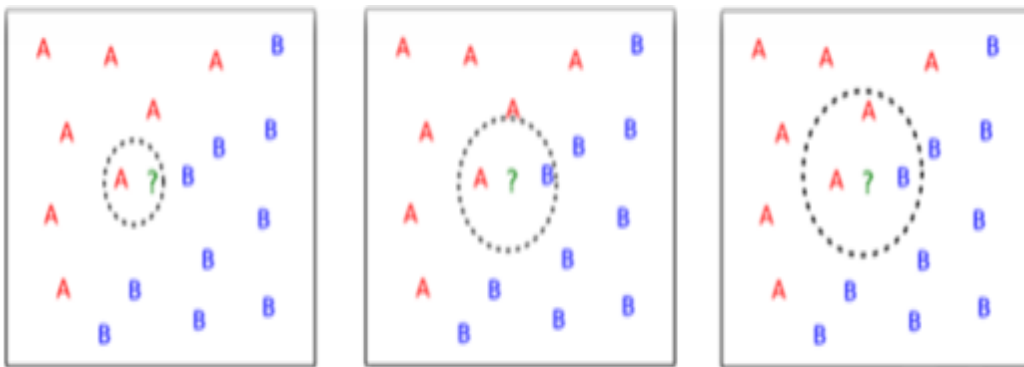
**Figure I.20** Approche de l'apprentissage des Moyennes

### I.5.3 Classificateur KPP

L'algorithme KPP, k des plus proches voisins (appelé aussi k-PPV ou k-NN pour -,Nearest-Neighbor) consiste à attribuer une étiquette à chaque nouvel individu à classer à partir d'une liste des plus proches voisins parmi ceux déjà classés.

L'individu est influencé par la classe qui compte le plus de membres parmi les plus proches voisins. Cette méthode nécessite la sélection d'une distance, dont la plus courante est la distance euclidienne, ainsi que le nombre de voisins à considérer.

Cette méthode supervisée non paramétrique est souvent efficace. De plus, comme il s'agit d'une sorte d'apprentissage par cœur (tous les exemples d'apprentissage sont conservés), son apprentissage est assez simple. Cependant, comme il nécessite le calcul de distance avec tous les exemples, le temps de prédiction est assez long, cependant il existe des heuristiques pour réduire le nombre d'exemples à considérer [23]. L'illustration décrit le principe général.



**Figure I.21** Principe des K-plus proches voisins (KNN).

#### I.5.4 Classification floue

La classification floue est une généralisation de la classification binaire pour permettre à l'indicateur  $U_{ik}$  (nommé degré d'appartenance) d'être un continuum dans l'intervalle  $[0, 1]$ .

Elle permet d'atteindre, pour un jeu de données  $X$  de  $n$  vecteurs caractéristiques, une partition floue. Cette classification produit pour l'ensemble des données  $X$ ,  $c$  classes caractérisées par leurs prototypes, représentant les points autour desquels les individus sont concentrés dans l'espace des intensités. En plus, elle fournit  $c$  carte de degrés d'appartenance mesurant la ressemblance entre chaque vecteur de données et les classes obtenues par la classification [25].

Dans ce cas, les classes obtenues ne sont plus disjointes :

$$\forall C_i, C_j \in C, i \neq j, C_i \cap C_j \neq \emptyset \quad (I.8)$$

Avec  $C$ , ensemble des classes  $C_i$ .

Plusieurs fonctions objectives ont été proposées dans la littérature, avec des propriétés différentes. La fonction objective proposée par Bezdek prend la forme quadratique suivante :

$$j = \sum_{i=1}^c \sum_{k=1}^n U_{ik}^m d^2(X_k, V_i) \quad (I.9)$$

$c$  : le nombre de classes connu.

$n$  : la taille du vecteur de données (nombre de pixels à classer).

$U_{ik}$  : le degré d'appartenance du pixel  $X_k$  à la classe  $i$  connue par son centroïde  $V_i$ .

$d$  : une distance, peut-être la distance euclidienne.

$m$  : un réel  $>1$  appelé degré de flou. Plus  $m$  tend vers 1, plus la classification devient dure et  $U_{ik}$  se rapproche de 0 ou de 1. Inversement quand  $m$  devient trop grand il y a moins de tolérance au bruit, et la distribution des degrés d'appartenance tend à se concentrer autour de  $1/c$ .

### I.5.5 Les machines à vecteurs supports (SVM)

Les machines à vecteurs supports ou séparateurs à vaste marge (en anglais Support Vector Machine, SVM) sont un ensemble de techniques d'apprentissage supervisé destiné à résoudre des problèmes de discrimination et de régression et sont particulièrement adaptées pour traiter les données de très hautes dimensions.

Les méthodes des Machines à support de vecteurs (Support Vector Machines : SVM) ont reçu une attention considérable ces dernières années et un grand nombre d'applications sont décrites dans la littérature. L'objectif des SVM est de maximiser la marge de séparation entre les classes. Une marge importante implique une faible dimension de Vapnik et Chervonenkis [24], qui a pour conséquence de bonnes performances en généralisation. Les SVM sont des algorithmes d'apprentissage faisant l'hypothèse que les éléments sont linéairement séparables s'ils sont préalablement projetés dans un espace à grande dimension adéquat. La projection est réalisée par l'utilisation de fonctions kernel  $k$ . La fonction la plus utilisée est le noyau gaussien qui réalise cette projection de façon implicite.

$$K(x_i, x_j) = e^{-\frac{\|x_i - x_j\|^2}{2\delta^2}} \quad (\text{I.10})$$

La recherche du meilleur hyperplan de séparation peut alors se formaliser comme un problème de programmation quadratique sous contrainte linéaire. L'hyperplan fournit par les SVM est ainsi représenté comme une combinaison linéaire de certains exemples de la base d'apprentissage appelés vecteurs de support. Il existe plusieurs algorithmes pouvant résoudre le problème cité ci-dessus. Le plus compétitif étant actuellement l'algorithme Séquentiel Minimal Optimisation (Optimisation Minimum Séquentiel). Il reste deux hyper-paramètres ( $C$  et  $\sigma$ ) qui doivent être choisis afin de minimiser le risque d'erreur déterminé à partir d'une base de tests. L'algorithme produit alors une fonction de décision pouvant être formalisée comme ci-dessous:

$$\varphi(x) = \sum_{i \in SV} \alpha_i y_i k(x_i, x) + b \quad (\text{I.11})$$

où  $0 \leq \alpha_i \leq C$  et  $(x_i, y_i)$  est un exemple de la base de tests.

La phase d'apprentissage consiste à modifier les poids reliant les neurones de façon à ce que la classe en sortie corresponde à celle de l'objet présenté en entrée.

## 1.6 Conclusion

Dans ce chapitre nous avons passé en revue les méthodes les plus utilisées en segmentation des images qui constitue la première phase de notre travail. C'est une présentation générale à savoir celles de l'approche contour, de l'approche région. Nous avons présenté quelques méthodes de classifications les plus connues. Dans ce qui suit nous allons nous aborder les champs aléatoires de Markov sur laquelle notre travail est basé.

*Chapitre II*  
*Chaines de Markov*  
*cachée*

## II.1 Introduction

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. 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

Dans ce chapitre, nous allons présenter la modélisation de la segmentation en utilisant les champs aléatoires de Markov cachés (Hidden Markov Random Fields). Les champs de Markov spatiaux ont été introduits par S.Geman et D. Geman [25]. Nous aborderons en premier quelques notions importantes comme le système de voisinage, les cliques, les champs de Gibbs et les champs de Markov avec les liens entre eux. Nous exposerons ensuite les champs aléatoires de Markov cachés (HMRF).

## II.2 Description de l'image

Cette section décrit quelques notions et termes importants liés à l'image.

### II.2.1 Système de voisinage (Neighborhood system)

Une image est formée d'un ensemble fini  $S$  de sites, les pixels,  $S = \{s_1, \dots, s_M\}$ . Les sites de  $S$  sont reliés par un système de voisinage ( $S$ ). On notera  $(S)$  l'ensemble des sites voisins du site  $t$ . Un système de voisinage ( $S$ ) a les propriétés suivantes :

- $\forall s \in S, s \notin (S)$  ; Un site n'est pas son propre voisin
- $\forall \{s, t\} \in S, s \in V_t(S) \Leftrightarrow t \in V_s(S)$




Figure II.1 Contexte spatial dans les images naturelles



La relation  $(S)$  exprime une contrainte de voisinage entre les sites adjacents. Un système de voisinage d'ordre  $r$ , noté  $(S)$ , est donné par la formule suivante :

$$(S) = \{t \in S \mid \text{distance}(s, t)^2 \leq r, s \neq t\} \quad (\text{II.1})$$

$s$


Où  $V_s$  est le voisinage du site  $s$  et la distance  $(s, t)$  ne dépend que de la position de  $s$  et  $t$ , et pas de leurs niveaux de gris (ou descripteurs).

Les systèmes de voisinage de premier et second ordre sont les plus utilisés. Dans le cas des images à deux dimensions (2D), un pixel dans le système de voisinage de premier ordre peut avoir jusqu'à 4 voisins et un pixel dans le système de second ordre peut avoir jusqu'à 8 voisins.



**Figure II.2** Un système de voisinage dans les images 2D, premier ordre (a), second ordre (b).

Dans le cas des images volumétriques (3D), qui ne sont rien d'autre qu'une succession de coupes d'images 2D, un pixel dans le système de voisinage de premier ordre peut avoir jusqu'à 6 voisins et un pixel dans le système de second ordre peut avoir jusqu'à 18 voisins.




**Figure II.3** Un système de voisinage dans les images 3D, premier ordre (a), second ordre (b).

### II.2.2 Notion de clique

Soit  $S$  l'ensemble des sites d'une image reliés entre eux par un système de voisinage  $(S)$ . Une clique  $c$  est un sous ensemble de  $S$  dans lequel tous les sites sont voisins entre eux. Donc pour toute clique  $c$  on aura :

Soit  $c$  contient un seul site

Ou bien : 
$$\forall \{s, t\} \in c, s \neq t \Rightarrow (t \in V_s(S) \Leftrightarrow s \in V_t(S)) \quad (II.2)$$



**Figure II.4** Les cliques associées aux systèmes de voisinage 2D.

Si une clique contient  $k$  sites, on l'appelle clique d'ordre  $k$  et on la notera  $C_k$ , et on notera  $C$  le système de cliques qui contient un ensemble des cliques relatif à un système de voisinage ( $S$ ). Par exemple, en 2D un système de voisinage de premier ordre, le système de cliques  $C$  contient toutes les cliques d'ordre 1 et d'ordre 2 et dans un système de voisinage de second ordre, le système de cliques  $C$  contient toutes les cliques d'ordre 1, d'ordre 2, d'ordre 3 et d'ordre 4. La figure suivante illustre les cliques associées aux systèmes de voisinage de premier et second ordre dans le cas des images en 2D.

Soit  $c \in C$  une clique de  $C$  ; on lui associe un potentiel  $U_c$  dont la 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 :

$$U = \sum_{c \in C} U_c \quad (II.3)$$

Dans le cas du système de voisinage de premier ordre (4-voisins) on aura :

$$U = \sum_{c_1=\{s\}} U_{c_1} + \sum_{c_2=\{s,t\}} U_{c_2} \quad (II.4)$$

L'énergie locale en un site  $s$  est définie comme la somme des potentiels de toutes les cliques

auxquelles le site  $s$  appartient :

$$U_s = \sum_{c \in \mathcal{C}/s \in c} U_c \quad (\text{II.5})$$

## II.3 Champs de Markov et champs de Gibbs

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

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.

### II.3.2 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 [25]:

- i.  $x \in \Omega, P(x) > 0$ .
- ii.  $S \in \mathcal{S}, x \in \Omega, P(X_s = x_s / X_t = x_t, t \neq s) = P(X_s = x_s / X_t = x_t, t \in V_s(S))$  (II.6)

### II.3.3 principe de la segmentation markovienne

#### II.3.3.1 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  $\Omega$  par : [25]

$$P[X=x] = Z^{-1} e^{-U(x)/T} \quad (\text{II.7})$$

$$U(x) = \sum_{c \in \mathcal{C}} U_c(x) \quad (\text{II-8})$$

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 [25]:

$$Z = \sum_{Y \in \Omega} e^{-U(Y)/T} \quad (\text{II.9})$$

Le calcul de  $Z$  est impossible à cause du très grand nombre de configurations, par exemple dans le cas d'une image  $512 \times 512$  pixels où 4 classes sont possibles, le cardinal de l'ensemble  $\Omega$ . 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  $c$  [25].

### II.3.3.2 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 :

$$U(x) = \sum_{c=(i) \in C_1} U_c(X_i) + \sum_{c=(i,j) \in C_2} U_c(X_i, X_j) \quad (\text{II.10})$$

À partir de ce théorème-là, nous pouvons donner l'expression de la probabilité de vraisemblance de l'image [25]:

$$P [X=x] = \frac{e^{-U(x)/T}}{\sum e^{-U(y)/T}} \quad (\text{II.11})$$

### II.3.3.3 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) [26].

– **Le modèle d’Ising**

C 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 [26] :

$$UC1=\{s\}(Xs)=-B \tag{II.12}$$


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

$$UC2 =\{s, t\}(Xs,Xt) \begin{cases} -\beta & \text{si } Xs = Xt \\ +\beta & \text{si } Xs \neq Xt \end{cases} \tag{II.13}$$

Avec une fonction d’énergie :

$$U(x)=-\sum_{c1=\{s\}} BXs - \sum_{c2=\{s,t\}} BXs Xt \tag{II.14}$$

Telle que  $\beta$  : est le paramètre du modèle ( $\beta>0$ ) mesure d’interaction entre sites voisins  
 $B$ :champ magnétique externe.

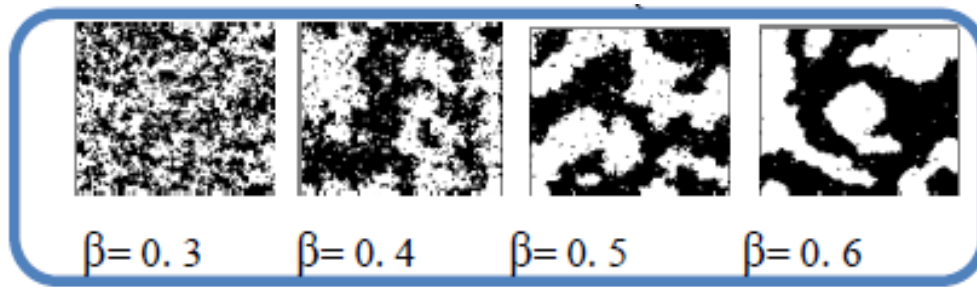


**Figure II.5** Modèle d’Ising, MRF à 2-D.

– **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]:

$$UC2 =\{s, t\}(Xs,Xt) \begin{cases} -\beta & \text{si } Xs = Xt \\ +\beta & \text{si } Xs \neq Xt \end{cases} \tag{II.15}$$



**Figure II.6** Exemple modèle de Potts avec différentes valeurs de  $\beta$ .

### II.3.3.4 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 [26]:

#### II.3.3.4.1 L'échantillonneur de Gibbs

Cet algorithme, proposé par Geman et Geman [25], 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 à l'étape  $n$  :

- i. 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 :

$$P(X_s = x_s | V_s) = \frac{\exp(-U_s((X_s | v_s))}{\sum_{X_s \in \Omega} \exp(-U_s((X_s | v_s))} \quad (\text{II.16})$$

- ii. 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 [26]

### II.3.3.4.2 Algorithme ICM (Iterated Conditional Modes)

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

- i. Choisir une configuration initiale  $\lambda_0$  aussi proche que possible de la configuration optimale.
- ii. Balayer l'ensemble des sites  $S$ . Chaque site  $s$  visité à l'étape  $n$  est caractérisé par son état  $\lambda(n)$  et par la configuration de son voisinage  $vs(n)$ . Son nouvel état  $\lambda(n+1)$  et la valeur qui correspond à l'énergie conditionnelle  $(|\lambda(n), r \in vs(n))$  minimale.
- iii. 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.

### II.3.3.5 Avantages du MRF [23]

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

## II. 4. 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 ..), comme on a définie 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.

*Chapitre III*  
*Résultats et*  
*Discussions*

### III.1 Introduction

La segmentation d'image est l'un des principaux défis du traitement d'image et de la vision par ordinateur, car les perturbations externes ajoutent du bruit à l'image. Le fait que de nombreuses méthodes informatiques et mathématiques constituent la meilleure approche en traitement d'image nécessite un problème de segmentation pour résoudre ce problème. Dans ce chapitre nous présentons la méthode de segmentation des images basée sur la méthode Markovienne des images des plaies des régions cutanées qui est l'une des étapes clés du diagnostic automatique de diagnostic afin d'identifier les infections.

### III.2 Les images

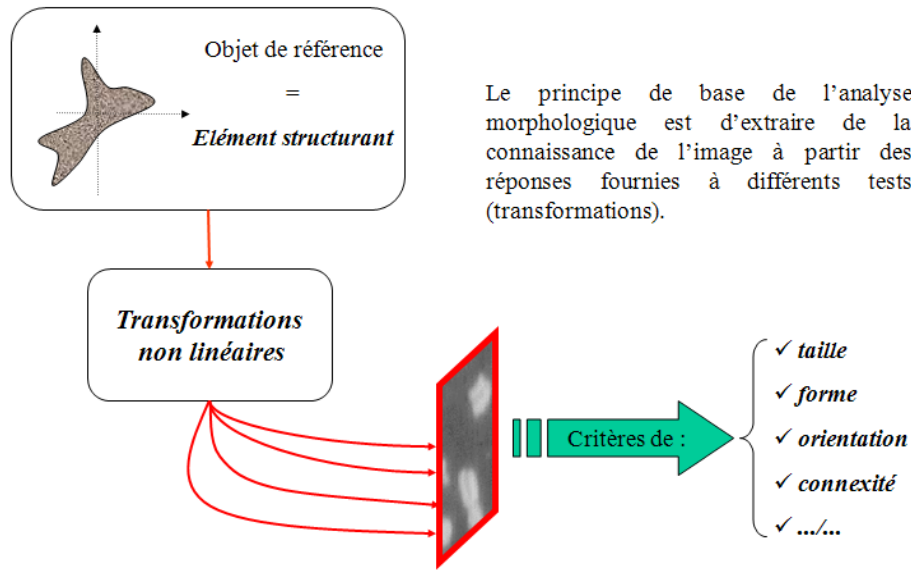
Les images test sont issues de la base de données [27] composé de milliers d'images de plaies de tout types (gangrane, brûlures ect.) ; la figure II.1 présente quelques exemple.



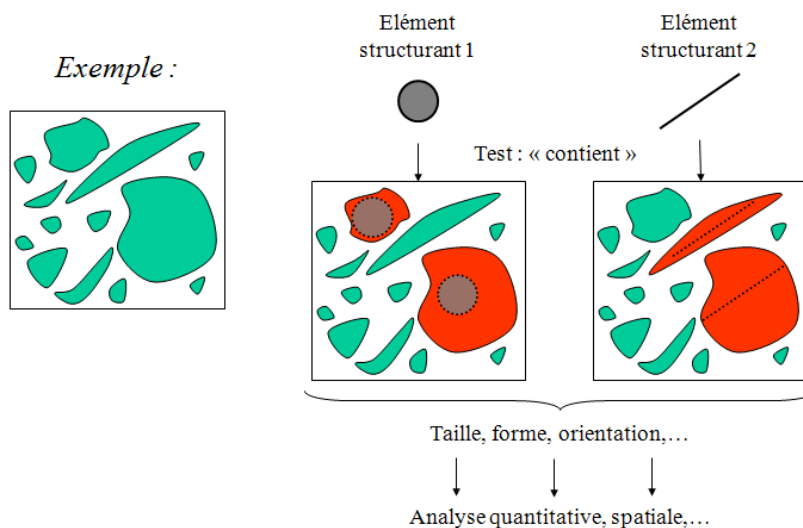
**Figure III.1** Exemples d'images de plaies de la base de donnée [25]

### III.3 morphologie mathématique

La morphologie mathématique est une théorie essentiellement non linéaire, utilisée en particulier en analyse d'images, pour l'étude des objets en fonction de leur forme, de leur taille, des relations avec leur voisinage (en particulier topologiques), de leur texture, et de leurs niveaux de gris ou de leur couleur (figure III.2).



(a) Principe de l'analyse morphologique



(b) Exemples

Figure III.2 Approche morphologique du traitement d'images

### III.3.1 Notion d'élément structurant

Des premières applications à l'étude des milieux poreux, est née l'approche ensembliste de la morphologie mathématique. Elle s'applique à des images ou objets binaires et les étudie sous l'angle de leurs relations avec un ensemble fixé. Cet ensemble, dont on choisit la forme et la taille, est appelé "élément structurant". Les relations sont de type ensembliste (réunion, intersection, etc.).

Étant donné un élément structurant  $B$  et une relation, l'image (ou l'objet)  $X$  de départ est transformé en tradant l'élément structurant en tout point et en examinant si la relation entre l'objet et l'élément structurant traduit est vérifiée. Les propriétés des opérations ainsi définies et des images transformées découlent de la théorie des ensembles. C'est selon ce principe que seront par exemple définies la dilatation et l'érosion binaires. L'élément structurant définit un voisinage autour de chaque point de l'image et ce sont donc des propriétés locales des objets qui sont ainsi mises en évidence. En pratique, les images sont définies sur des trames discrètes. Le problème consiste alors à étudier dans quelle mesure les définitions et les propriétés des transformations décrites pour l'espace continu sont transposables à un espace discret. Les trames les plus utilisées en dimension 2 sont la trame carrée (ou rectangulaire) et la trame hexagonale où les points sont disposés en quinconce.

La forme et la taille de l'élément structurant doivent être adaptées aux propriétés géométriques des objets de l'image. Dans ce qui suit, nous allons définir les quatre opérations de la morphologie mathématique et nous nous contenterons de donner des définitions moins générales, appliquées à l'image numérique en teintes de gris [25].

### III.3.1.1 L'érosion

L'érosion morphologique notée  $E_B(X)$  d'un ensemble  $X$  par un élément structurant  $B$ , est l'ensemble des points  $x$  tels que  $B$  soit totalement inclus dans  $X$ , si  $B$  est centré en  $x$ .

$$E_B(X) = X \ominus \bar{B} \quad (\text{III.1})$$

Où  $\bar{B}$  est le transposé de l'élément structurant et  $X$  ensemble correspondant à l'image ;

L'érosion réduit les « pics » de niveaux de gris et élargit les « vallées » : elle tend donc à homogénéiser l'image, à l'assombrir et à étaler le bord des objets les plus sombres comme le montre la figure III.3.




Figure III.3 Erosion. (a) image en niveaux de gris (b) érosion avec  $B$  carré de taille 6

**III.3.1.2 La dilatation**

La dilatation morphologique notée  $D_B(X)$  d'un ensemble  $X$  par un élément structurant  $B$  est définie par l'ensemble de points  $x$  tel que  $B$  intersecte  $X$  quand son origine coïncide avec  $x$  :

$$D_B(X) = (X \oplus \hat{B}) \quad (\text{III.2})$$

Où  $\hat{B}$  désigne l'élément structurant symétrique de  $B$ .

Cette transformation comble les « vallées » et épaissit les « pics » : elle homogénéise l'image, l'éclaircit et tend à faire disparaître les objets sombres, figure III.4




Figure III.4 Dilatation. (a) image en niveaux de gris (b) dilatation avec  $B$  carré de taille 6

**III.3.1.3 Fermeture**

La fermeture (dilatation suivie d'une érosion) de l'ensemble  $X$  par l'élément structurant  $B$  est définie par :

$$F_B(X) = E_B(D_B(X)) = (X \oplus \hat{B}) \ominus B \quad (\text{III.4})$$

La fermeture a pour effet de boucher les trous des objets qui sont plus petits que l'élément structurant. Elle lisse les contours des objets en rajoutant des points dans les concavités étroites (dans lesquelles ne peut pas se glisser l'élément structurant). Elle permet donc de combler les vallées, homogénéiser et éclaircir l'image, figure III.5.




Figure III.5 Fermeture. (a) image en niveaux de gris (b) fermeture avec B carré de taille 6

#### III.3.1.4 Ouverture

L'ouverture (érosion suivie d'une dilatation) de l'ensemble  $X$  par l'élément structurant  $B$  est définie par :

$$O_B(X) = E_B(D_B(X)) = (X \oplus \hat{B}) \ominus B \quad (\text{III.5})$$

L'ouverture permet de supprimer les pics mais préserve les vallées, elle homogénéise l'image et préserve les objets sombres ou 'trous' qui ne dépassent pas un certain diamètre, figure III.6.




Figure III.6 Ouverture. (a) image en niveaux de gris (b) fermeture avec B carré de taille 6

#### III.3.1.5 Les filtres alternés séquentiels

A partir des filtres morphologiques élémentaires, tels que les ouvertures et les fermetures, on définit des filtres morphologiques plus évolués. Parmi ceux-ci, les Filtres Alternés Séquentiels (FAS) sont sans doute les plus populaires. Ils permettent de réduire la complexité d'une image sans dégrader les contrastes les plus importants. On définit Filtre Alterné Séquentiel Noir de taille  $n$ , noté  $FAS_N(n)$ , comme une itération de succession d'ouverture et de fermeture de taille croissantes et il est donné par:

$$FAS_N(n) = F_N O_n \dots F_2 O_2 F_1 O_1 \quad (\text{III.6})$$

Où  $O_i$  et  $F_i$  sont une famille d'ouvertures et une famille de fermetures par un élément structurant de même forme et de taille croissante.

Notons qu'on obtient bien ainsi des opérations croissantes et idempotentes (donc des filtres morphologiques). Ils sont utilisés en pratique pour filtrer progressivement le bruit positif (pics étroits) et le bruit négatif (vallées étroites). Le dernier élément structurant utilisé (de taille  $n$ ) est déterminé en fonction de la taille minimale des objets de l'image que l'on veut conserver après le filtrage.

### III.4 Méthode de segmentation des images de plaies

L'algorithme de la méthode est basé sur quelques prétraitements de l'image tels que le rehaussement du contraste et filtre médian. L'algorithme à base de MRF est donnée par :

- i.* Démarrage
- ii.* Acquisition d'image
- iii.* Redimensionnement de l'image et initialisation des paramètres
- iv.* Détection des bords et renforcement du bord (ICM)
- v.* Dilatation de l'image souillée avec l'élément structurant carré
- vi.* Tracer Trace l'image originale de la plaie Trace la plaie segmentée seule
- vii.* Évaluation de la précision
- viii.* Analyse des performances
- ix.* Arrêt

#### L'algorithme ICM

- i.* Initialisation: il s'agit de fournir à l'algorithme une image classifiée et d'estimer les paramètres  $\alpha$  de la classification initiale. Les paramètres  $\alpha$  correspondent à la moyenne et à la variance de chaque classe.
- ii.* A partir d'une configuration initiale, les étapes suivantes sont réalisées pour chaque pixel : Pour chaque classe :

- Calcul de l'énergie conditionnelle  $U1$  (équation II.12)

- Calcul de l'énergie à priori  $U2$  (équation II.5)

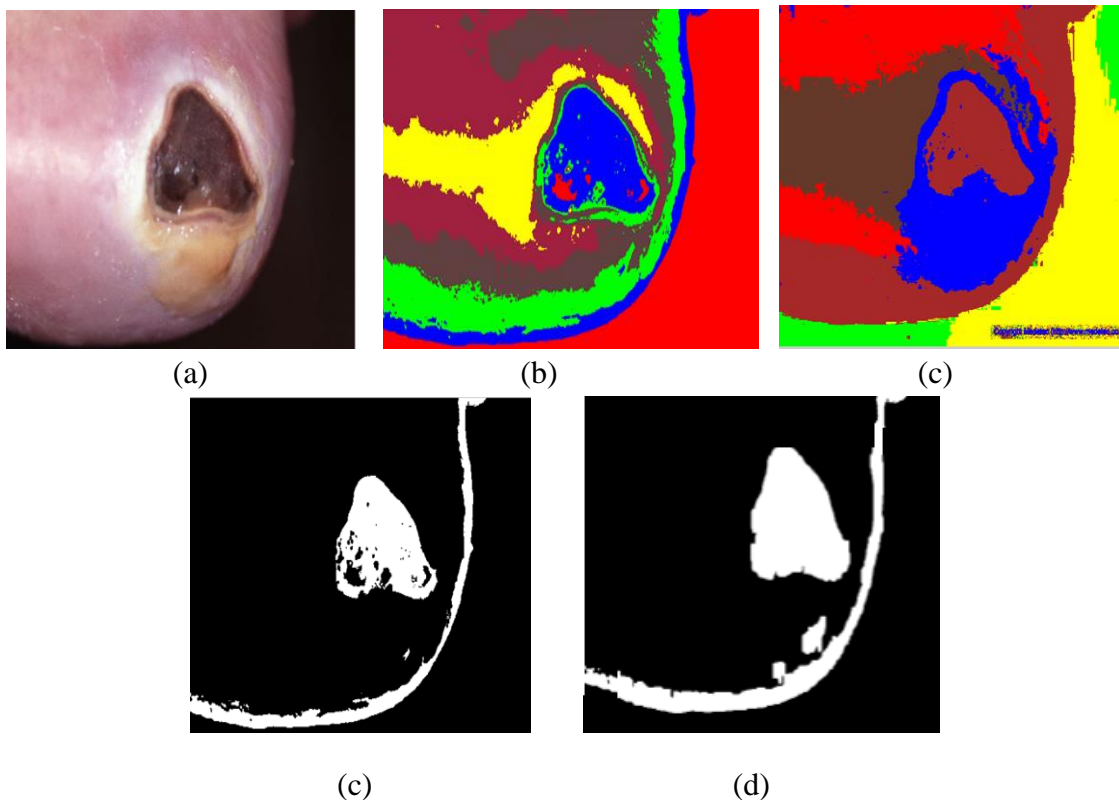
- Calcul de l'énergie globale  $U = U1+U2$

- iii. Rechercher la classe donnant une énergie globale minimale.
- iv. On affecte l'étiquette de cette classe au site courant.
- v. On vérifie si le critère d'arrêt est satisfait. Si c'est le cas, l'algorithme s'arrête sinon on retourne à l'étape ii).

### III.5 Résultats et discussion

#### III.5.1 Résultats de la Segmentation

Nous avons essayé d'appliquer la méthode de classification k-moyennes pour différents nombres de classes, et nous avons remarqué un meilleur résultat pour un nombre de classes 6 (figure III (b). En effet il n ya pas de méthodes pour définir le nombre de classes, généralement on procède par essais figure III.7. La classification par MRF (figure III (c)) donne le meilleur résultat en se basant sur l'avis d'un expert.



**Figure III.7** Résultat de la classification par Moyennes (6 classe)

- (a) Image réelle, (b) image classifiée par k-moyennes, (c) image classifié par MRF,  
 (c) image segmenté et binarisée, (d) ouverture et fermeture séquentielle par morphologie mathématique

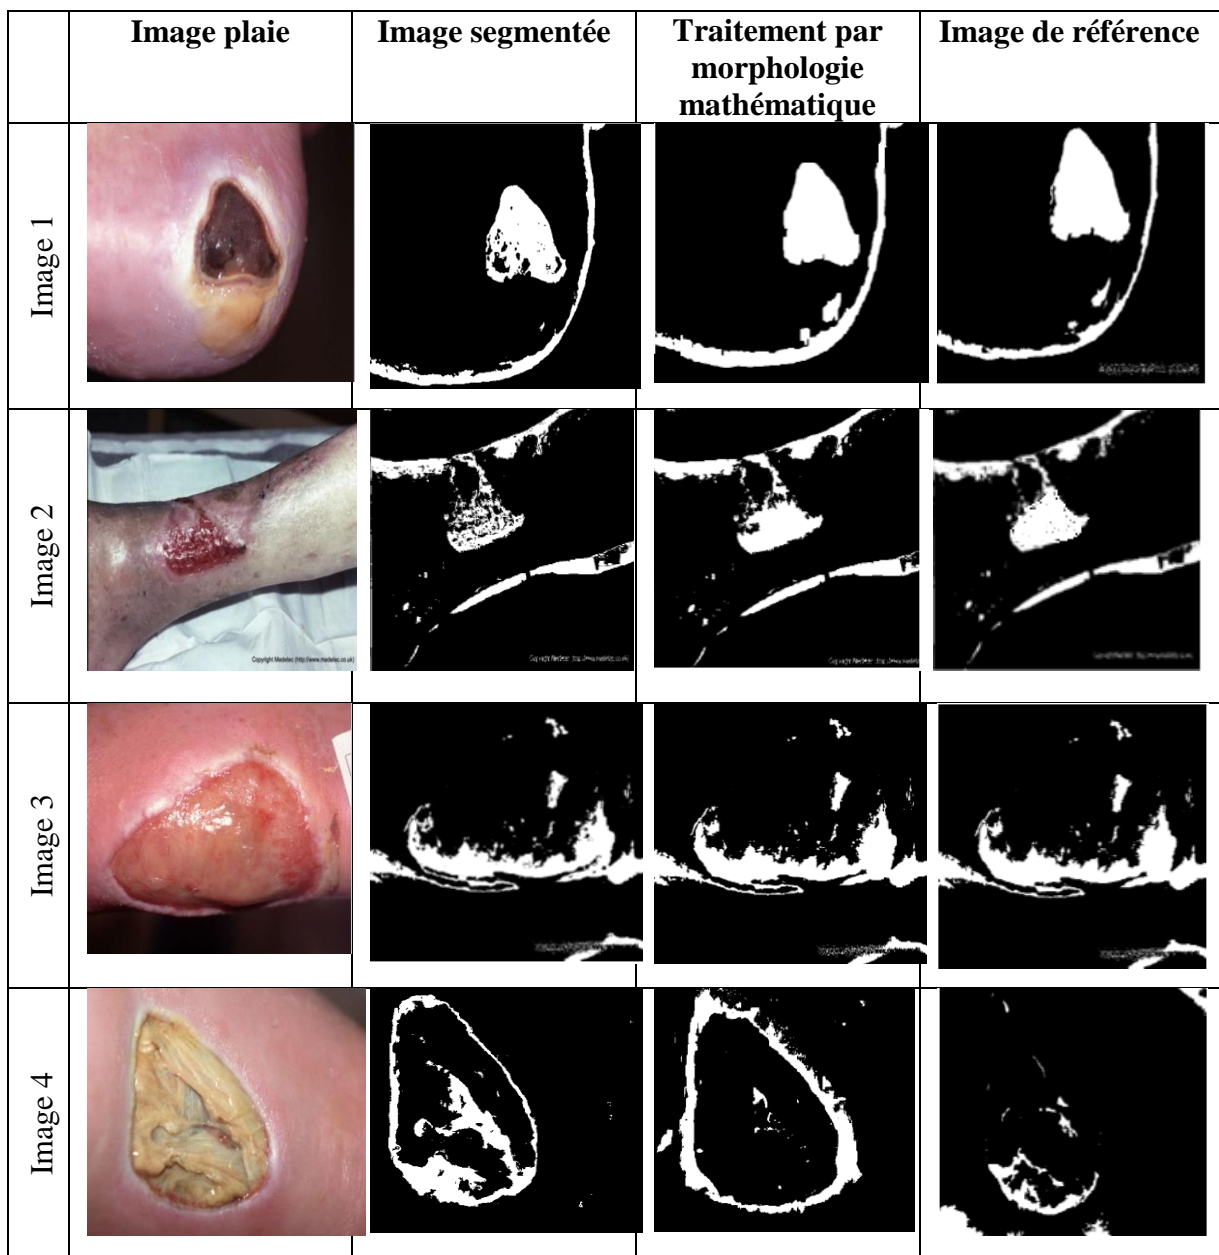
Dans ce travail, diverses images montrant des blessures ont été acquises à partir de la base de données. Au moyen du champ aléatoire de Markov, les bords ont été détectés et définis pour la zone de la plaie à l'aide d'un filtre morphologique séquentiel. Plus tard l'opération de dilatation est appliquée sur l'image avec un élément structurant carré donnant l'image de sortie qui indique clairement les bords de la plaie où l'intensité de la blessure est élevée. Ces résultats sont comme indiqué dans figure III.8.

Le tableau III.1 représente le temps de calcul pour chaque image ainsi que le taux de reconnaissance donné par :

$$\text{taux de reconnaissance} = \frac{\text{nombre de pixels dans l'images segmenté}}{\text{nombre de pixel blanc dans l'imagereférence}} \quad (\text{III.7})$$

Tableau 1 : Représentation de l'image et du temps écoulé respectif

<b>Image</b>	<b>Temps écoulé (secondes)</b>	<b>Taux de reconnaissance</b>
Image 1	70.317803	0.96
Image 2	68.219182	0.94
Image 3	66.32899	0.90
Image 4	69.517576	0.86



**Figure III.8** Résultat de la segmentation par la méthode proposée

### III.6 Conclusion

Dans ce travail, nous avons proposé un schéma de segmentation d'images de plaies basé sur les champs aléatoires de Markov (MRF). Nous avons établi le MRF dans les zones segmentées préliminaires décrivant les bords et les régions et définissant les processus aux limites. Un post traitement final est obtenu par morphologie mathématique pour délimiter les zones. Nous avons obtenu un résultat satisfaisant avec un taux de reconnaissance moyen de 91%.

*Conclusion*

*Général*

# Conclusion général

---

## 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. Nous avons présenté une méthode de segmentation des images basée sur la méthode Markovienne des images des plaies des régions cutanées qui est l'une des étapes clés du diagnostic automatique de diagnostic afin d'identifier les infections.

On a présenté la modélisation du problème de la segmentation par les MRFs, et leurs différents modèles (modèle d'Ising, de Potts ..), 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 d'une manière automatique.

Nous avons établi le MRF dans les zones segmentées préliminaires décrivant les bords et les régions et définissant les processus aux limites. Un post traitement final est obtenu par morphologie mathématique pour délimiter les zones. Nous avons obtenu un résultat satisfaisant avec un taux de reconnaissance moyen de 91%, avec un temps de calcul n'excédant par 70°

En perspective, on propose une amélioration de la méthode en ajoutant des attributs texturaux par exemple et on souhaiterai appliquer la méthode sur des images médicales du cerveaux et de mammographie pour un diagnostic automatique.

# *Bibliographie*



- [1] C.Houassine, segmentation d'images, Mémoire de magistère université m'hamed bougara- boumerdes. 2012
- [2] Champs de Markov couple pour la segmentation d'images ,université constantine 2. 2014
- [3] Y. Pavan Kumar Reddy, D. Saiteja, E. Raja Sekhar Reddy, P. Sai Aditya Yadav , S. Fahimuddin, Wound Image Segmentation Using Markov Random Field Master, Journal of Information and Computational Science,2020
- [5] S .Faid et W. Dehimi, Modèle de segmentation d'image à champ aléatoire de markov (MRF) » diplôme de Master Académique, Université Mohamed Boudiaf M'Sila, 2020
- [6] M.Ameur , N. Idrissi, D.Cherki, Triplet Markov chain in images segmentation, Conference: 2018 International Conference on Intelligent Systems and Computer Vision (ISCV), 2018 DOI: 10.1109/ISACV.2018.8354055
- [7] R.Kemam, I .Brahimi, ' Contribution à la segmentation des images médicales cancer de sein par analyse de textures', Master en Télécommunications (option: systèmes de télécommunication), 2020
- [8] H. Gourine, ' Segmentation d'images satellitaires Panchromatique par analyse de texture : Application à l'extraction des surfaces bâties ', Mémoire de Master en électronique (Contrôle de système, imagerie et vision), université Amar Telidji de Laghouat, 2015
- [9] Y. Pavan Kumar Reddy, D. Saiteja, E. Raja Sekhar Reddy, P. Sai Aditya Yadav , S. Fahimuddin, Wound Image Segmentation Using Markov Random Field Master, Journal of Information and Computational Science, Volume 10 Issue 3 , 1490- 1496, 2020
- [10] S.belmrabet et N.bardjak, 'segmentation d'image', Mémoire de Master en Informatique , Université Larbi Ben M'hidi Oum El Bouaghi; 2017
- [11] A. Chellal, K. Halal, K. Ait hamiche, ' Segmentation d'images en utilisant la super pixelisation, thèse de master en Automatique, Université Mouloud Mammeri De Tizi-Ouzou, 2018
- [12] C. Salou, Comment utiliser les histogrammes d'une image numérique, École nationale des sciences géographiques, Marne la valetée, université paris, 2018
- [13] H. Filali, K. Kalti, Image segmentation using MRF model optimized by a hybrid ACO-ICM algorithm, Soft Computing - A Fusion of Foundations, Methodologies and Applications, Vol 25, Issue 15,2021 pp 10181–10204
- [14] K. Karhunen, Über lineare methoden in der wahrscheinlich-keitsrechnung. Ann. Acad. Sci. Fennicea, Ser. A137, 1947. (Translated by Selin, I. in “On Linear Methods in Probability Theory,” Doc. T-131, The RAND Corp., Santa Monica, CA, 1960.)

- [15] H. Rami, Contribution au développement de descripteurs LBP pour le suivi d'objet en mouvement, Thèse de doctorat, Faculté des Sciences, RP, Rabat – Maroc, 2016
- [16] H. Maitre, Le traitement des images, PARISTEC, 2004.
- [17] A. Houassine, Segmentation d'images par une approche Biomimétique hybride, Thèse de magister, Université M'Hamed Bougara, Boumerdas, 2012.
- [16] I. Kessour, I. Tali, Simulation de contours actifs par la colonie de fourmis, thèse pour l'obtention du diplôme d'ingénieur d'état en informatique, Ecole nationale Supérieure d'informatique, 2011
- [17] L. Lechlek, M .Ghougal, la segmentation d'image médicale par la méthode d'ensemble de niveaux (level sets), Thèse de Master, Université Larbi Ben M'hidi, Oum El Bouaghi, 2016.
- [18] R.Saada, Y. Benchaabane, Segmentation d'images médicales volumétriques par champs de Markov cachées, d'informatique, Ecole nationale Supérieure d'informatique ,2010.
- [19] T. Tassadit , N. Bentayeb, Segmentation des images IRM cérébrales , mémoire de master en systèmes informatiques, Université Mouloud MAMMARI de Tizi-Ouzou, 2015
- [20] M.S. Touhara, F. Yahyaoui, Segmentation des images médicales 2D et 3D par les modèles déformables géométriques (implicites) fondés sur les ensembles de niveaux (Level Sets), Mémoire de fin d'étude pour l'obtention du diplôme d'ingénieur d'état en informatique, Ecole nationale Supérieure d'informatique, 2012.
- [21] R. Haroun, Segmentation des tissus cérébraux sur des images par résonance magnétique, mémoire de fin d'étude pour l'obtention du diplôme de Magister en électronique, spécialité : Traitement du Signal des Images, Université des sciences et de la technologie Houari Boumedienne, Faculté d'Electricité et d'informatique, 2005.
- [22] K. Dahmane, Analyse d'images par méthode de Deep Learning appliquée au contexte routier en conditions météorologiques dégradées, Vision par ordinateur et reconnaissance de formes. Université Clermont Auvergne, 2020
- [23] J.Marc Salotti, Gestion des informations dans les premières étapes de la vision par ordinateur, Interface homme-machine, Thèse de doctorat en informatique, Institut National Polytechnique de Grenoble - INPG, 1994
- [23] O. Nait Belaid, Classification Par FCM En analysant la texture et la forme Application Aux images médicales, Mémoire de master en automatique, Université Mouloud MAMMARI de Tizi-Ouzou, 2016.
- [24] V. Vapnik, The Nature of Statistical Learning Theory, Springer-Verlag, New

York, 2000.

- [25] S. Geman and D. Geman. Stochastic relaxation, Gibbs distributions, and the Bayesian restoration of images. *IEEE Transaction on Pattern analysis and Machine Intelligence*, 6(6) : 721–741, 1984. 50, 81
- [26] L. Azizi , Champs aléatoires de Markov cachés pour la cartographie du risque en épidémiologie. *Mathématiques générales [math.GM]*. Université de Grenoble, 2011.
- [27] <https://github.com/uwm-bigdata/wound-segmentation>