

RÉPUBLIQUE ALGÉRIENNE DÉMOCRATIQUE ET POPULAIRE
MINISTÈRE DE L'ENSEIGNEMENT SUPÉRIEUR ET DE LA RECHERCHE SCIENTIFIQUE
UNIVERSITÉ MOULOUD MAMMERI DE TIZI OUZOU



FACULTÉ DE GÉNIE ÉLECTRIQUE ET D'INFORMATIQUE
DÉPARTEMENTS AUTOMATIQUE ET ÉLECTRONIQUE

MÉMOIRE DE FIN D'ÉTUDES DE MASTER PROFESSIONNEL

DOMAINE : SCIENCES ET TECHNOLOGIE

FILIÈRE : AUTOMATIQUE ET ÉLECTRONIQUE

Présenté par :

ZAHIA MESSAOUI
LIZA AKLI

Thème

SEGMENTATION INTERACTIVE D'IMAGES PAR
CLASSIFICATION : APPLICATION AUX IMAGES DE
PIED DIABÉTIQUE

Soutenu devant le jury composé de :

<i>Président</i>	Mr MESSAR YOUSSEF	M.A.A	UMMTO
<i>Encadrant</i>	Mme HALICHE ZOHRA	M.A.A	UMMTO
<i>Co-Encadrant</i>	Dr ABDEREZAK SALMI	Docteur	UMMTO
<i>Examineur</i>	Mr HAMMOUCHE KAMAL	Professeur	UMMTO
<i>Examinatrice</i>	Mme NAIT BELAID OUIZA	M.A.A	UMMTO

Promotion 2023 – 2024

Table des Matières

Table des Matières	i
Table des Figures	iii
Liste des Tableaux	v
Liste des Abréviations	vii
Introduction Générale	2
1 Contexte et but de ce travail	4
1.1 Introduction	5
1.2 Traitement d'images	5
1.2.1 Acquisition d'image	8
1.2.2 Pré-traitement	8
1.2.3 Segmentation	10
1.2.4 Post-traitement	11
1.2.5 Interprétation	11
1.3 Diabète	12
1.4 Pied diabétique	14
1.5 Systèmes d'acquisition des images DFU	16
1.6 Segmentation des images DFU	17
1.6.1 Segmentation manuelle	17
1.6.2 Segmentation automatique	18
1.7 Caractéristiques des tissus des DFU	18
1.8 Conclusion	20
2 Segmentation d'images couleur interactive	22
2.1 Introduction	23
2.2 Segmentation d'images	23
2.3 Méthodes de segmentation d'images	24
2.3.1 Méthodes basées sur les contours	24
2.3.2 Méthodes basées sur les régions	26
2.3.3 Méthodes basées sur la classification des pixels	27
2.4 Extraction des attributs	27
2.4.1 Couleur	28
2.4.2 Texture	36

2.5	Segmentation interactive d'images	41
2.6	Conclusion	42
3	Classification des pixels	43
3.1	Introduction	44
3.2	Classification	44
3.2.1	Classification supervisée	44
3.2.2	Classification non supervisée	44
3.2.3	Classification semi-supervisée	45
3.3	Exemples de méthodes supervisées	45
3.3.1	k-Nearest Neighbors (k-NN)	46
3.3.2	Support Vector Machines (SVM)	46
3.4	Exemples de méthodes non supervisées	47
3.4.1	K-means	47
3.4.2	Fuzzy c-means	48
3.4.3	Classification hiérarchique	49
3.4.4	k-Médoids	49
3.4.5	DBSCAN	50
3.5	Exemples de méthodes semi-supervisées	51
3.5.1	K-means semi-supervisé	51
3.5.2	COP-k-means	52
3.6	Conclusion	53
4	Approche proposée	54
4.1	Introduction	55
4.2	Approche proposée	55
4.3	Étude des attributs extraits	58
4.3.1	Attributs de couleur	58
4.3.2	Attributs de texture	59
4.3.3	Attributs de texture couleur	61
4.3.4	Résultats de segmentation semi-supervisée	62
4.3.5	Post-traitement	63
4.4	Conclusion	66

Table des figures

1.1	Image numérique.	5
1.2	Différentes régions de l'image.	6
1.3	Contours : (a) image originale, (b) filtre de Canny, (c) filtre de Roberts.	6
1.4	Histogramme d'image : (a) image couleur, (b) image niveaux de gris, (c) histogramme sur le canal Rouge, (d) histogramme sur le canal Bleu, (e) histogramme sur le canal Vert, (f) histogramme en niveau de gris.	7
1.5	Chaîne de traitement d'images.	7
1.6	Système d'acquisition d'images : (a) appareil photo numérique, (b) appareil thermique, (c) caméra de surveillance, (d) microscope numérique.	8
1.7	Amélioration du contraste : (a) image original, (b) image améliorée avec un faible ajustement (c) image améliorée avec un ajustement élevé.	9
1.8	Binarisation : (a) image couleur, (b) image en niveau de gris, (c) image binaire.	9
1.9	Filtrage d'image : (a) image originale, (b) filtre gaussien [$\sigma = 1$], (c) filtre gaussien [$\sigma = 2$], (d) et (e) filtre moyennneur, (f) filtre médian.	10
1.10	Segmentation d'une image couleur : (a) image originale, (b) image segmentée par k-means (en deux régions), (c) image segmentée par k-means (en trois régions).	11
1.11	(a) vérité terrain, (b) image segmentée, (c) ouverture, (d) fermeture.	11
1.12	Complications du diabète [1].	13
1.13	Illustration d'ulcère du pied.	14
1.14	Diagnostic de la neuropathie diabétique.	15
1.15	Diagnostic de l'arthériopathie diabétique.	15
1.16	Pieds diabétiques infectés : cercle en rouge entoure l'infection.	16
1.17	Illustration des appareils d'acquisitions : (a) Caméra thermique, (b) Selfie des pieds, (c) Podiscan, (d) FootSnap.	17
1.18	Couleur de l'ulcère.	18
1.19	Taille de l'ulcère.	19
1.20	Profondeur d'un ulcère.	19
1.21	Gravité d'un ulcère.	19
1.22	Textures de la peau.	20
1.23	Différentes textures de l'ulcère.	20
1.24	Inflammation des ulcères.	20
2.1	Segmentation d'image couleur : (a) image originale, (b) vérité terrain, (c) image segmentée par K-means.	23

2.2	Différents modèles de contour : (a) marche d’escalier, (b) rampe, (c) toit.	25
2.3	Segmentation par contours : (a) image originale, (b) image en niveaux de gris, (c) contour actif, (d) Prewitt, (e) Sobel.	25
2.4	Méthode de division de régions.	26
2.5	Segmentation par seuillage : (a) image couleur, (b) image en niveau de gris, (c) image segmentée avec un seuil=0.5.	27
2.6	Spectre des couleurs [2].	28
2.7	Différentes catégories des espaces colorimétriques [3].	29
2.8	Représentation de l’espace RVB.	29
2.9	Présentation de l’espace Lab [4,5].	30
2.10	Représentation de l’espace LUV.	31
2.11	Représentation de l’espace YIQ.	32
2.12	Représentation de l’espace YCbCr.	33
2.13	Représentation de l’espace HSV.	34
2.14	Représentation de l’espace HSL.	34
2.15	Représentation de l’espace CMYK.	35
2.16	Les différentes classes d’attributs de texture dans la littérature [6].	36
2.17	Illustration de calcul d’un LBP (8 voisins).	37
2.18	Illustration des paramètres de GLCM.	39
2.19	Exemple de matrices de cooccurrence d’une image 4 * 4 composée de 4 niveaux de gris [7].	39
2.20	Processus illustratif d’une méthode de segmentation interactive.	41
2.21	Différents types d’informations à priori utilisés dans la segmentation interactive : (a) points (trois régions), (b) traits (trois régions), (c) dessin, (d) points (deux régions), (e) traits (deux régions), (f) box.	42
3.1	Différentes approches de classification [les pixels en couleur orange et noir sont connus, et les pixels sans couleur sont inconnus].	45
3.2	Principe des SVM.	47
3.3	Principe des DBSCAN [8].	50
4.1	Schéma illustratif des étapes du travail.	55
4.2	Les images utilisées pour l’étude des paramètres.	56
4.3	Images de test.	57
4.4	Détermination de la région d’intérêt par interaction de l’utilisateur : (a) et (d) images originales, (b) et (e) imageries, (c) et (f) vérités terrains.	57
4.5	Segmentation d’images par K-means : (a) images originaux, (b) vérités terrains, (c) en utilisant les attributs de couleur, (d) en utilisant les attributs de texture (Haralick), (e) en utilisant les attributs de texture couleur (Haralick).	62
4.6	Résultats visuels de segmentation interactive de l’image 0743 (NS :non supervisée, Seg-SP : sans post-traitement, Seg-AP : avec post-traitement)	64
4.7	Résultats visuels de segmentation interactive de l’image 0914 (NS :non supervisée, Seg-SP : sans post-traitement, Seg-AP : avec post-traitement)	65
4.8	Résultats visuels de segmentation interactive de l’image 0928 (NS :non supervisée, Seg-SP : sans post-traitement, Seg-AP : avec post-traitement)	65

4.9 Résultats visuels de segmentation interactive de l'image 0568 (NS :non supervisée, Seg-SP : sans post-traitement, Seg-AP : avec post-traitement) . 66

Liste des tableaux

4.1	Résultat de segmentation obtenus avec les attributs de couleur.	59
4.2	Le rang des espaces de couleur.	60
4.3	Moyenne des accuracy.	60
4.4	Résultats de segmentation en utilisant les attributs de texture.	60
4.5	Résultats de segmentation en utilisant les attributs de texture couleur. . .	61
4.6	Résultats de segmentation par classification semi-supervisée.	63
4.7	Résultats de segmentation par classification semi-supervisée après post- traitement.	63

LISTE DES ABRÉVIATIONS

- FID** : Fédération International du Diabète.
- IRM** : Imagerie par Résonance Magnétique.
- DFU** : Diabetic Foot Ulcer.
- FCM** : Fuzzy C-Means.
- KMS** : K-Means.
- KMD** : K-Medoids.
- DBSCAN** : Density-Based Spatial Clustering of Applications with Noise.
- CIE** : Commission Internationale de l'éclairage.
- ACP** : Analyse en Composantes Principales.
- ACI** : Analyse en Composantes Indépendantes.
- LBP** : Local Binary Patterns.
- GLCM** : Gray-Level Co-occurrence Matrix.
- K-NN** : K-Nearest Neighbors.
- PAM** : Partitioning Around Medoids.
- CLARA** : Clustering Large Applications.
- CLARANS** : Clustering Large Applications based upon RANdomized Search.
- CAH** : Classification Ascendante Hiérarchique.
- UPGMA** : Unweighted Pair Group Method with Arithmetic Mean.
- CDH** : Classification Descendante Hiérarchique.

Remerciements

Nous tenons à remercier notre encadreur Mme HALICHE Zohra pour avoir acceptée de diriger ce mémoire. Nous tenons à remercier vivement notre co-encadreur Monsieur Salmi Abderezak pour ses remarques, ses suggestions pertinentes et ses lectures qui ont permis l'aboutissement de ce travail de recherche.

Nous remercions également tous nos enseignants, collègues, membres de la famille et ami(es) qui ont contribues directement ou indirectement dans la réalisation et la finalisation de ce modeste travail.

INTRODUCTION GÉNÉRALE

La segmentation d'images est une étape importante dans le domaine du traitement d'images médicales, notamment pour le diagnostic et la prise en charge des ulcères du pied diabétique (DFU). L'objectif principal de ce mémoire est d'explorer et de développer une nouvelle approche de segmentation interactive d'images par classification semi-supervisée, spécifiquement adaptée aux images médicales des ulcères du pied diabétique. Cette approche vise à fusionner les avantages de la segmentation non supervisée avec la précision de l'intervention humaine, dans le but d'obtenir des résultats plus précis et mieux adaptés aux exigences cliniques.

Le diabète représente un défi majeur de santé publique à l'échelle mondiale, affectant des millions de personnes et entraînant des complications graves, notamment le pied diabétique. La prise en charge efficace de ces complications nécessite une approche diagnostique précise et efficace, qui repose souvent sur l'utilisation d'images médicales pour évaluer l'étendue des lésions et guider le traitement. Cependant, l'analyse et l'interprétation de ces images, sont complexes en raison de la variabilité des caractéristiques cliniques, visuelles et texturales des tissus affectés. Cette diversité rend l'analyse et l'interprétation de ces images particulièrement délicates.

Ainsi, ce mémoire vise à explorer les différentes étapes du traitement d'images, à savoir l'acquisition, le pré-traitement, la segmentation, le post-traitement et l'interprétation des images.

La première étape est l'acquisition des images, qui consiste à capturer des images à l'aide d'appareils tels que des caméras, des scanners ou des capteurs spécialisés. La qualité des images obtenues peut varier en fonction des conditions d'éclairage et de la résolution des capteurs utilisés. Les dispositifs couramment employés incluent des appareils photo numériques, des caméras haute définition, des scanners d'images, et des systèmes de capture à grande vitesse, chacun ayant ses propres spécificités et utilisations.

Le pré-traitement, qui suit l'acquisition, a pour objectif d'améliorer la qualité des images afin de faciliter les étapes suivantes du traitement. Cette phase peut inclure des techniques telles que le filtrage pour atténuer le bruit, l'égalisation d'histogramme pour rehausser le contraste, et la correction des distorsions. Les outils typiques pour le pré-traitement comprennent des logiciels comme MATLAB.

La segmentation intervient après le pré-traitement et vise à diviser l'image en régions distinctes ou objets d'intérêt pour simplifier l'analyse. Cette étape est essentielle pour isoler les régions d'intérêt du fond. Les techniques de segmentation courantes incluent le seuillage, les méthodes basées sur les contours telles que les algorithmes de Canny, et les approches fondées sur les régions comme la croissance de régions et la classification. Dans cette phase plusieurs algorithmes de segmentation sont utilisés tels que : K-means, FCM, COP-K-means, DBSCAN, etc.

Le post-traitement, qui suit la segmentation, permet d'optimiser les résultats obtenus et de préparer les images pour l'analyse finale. Cette étape peut impliquer la correction des erreurs de segmentation, le lissage des contours, ainsi que la fusion des régions segmentées pour obtenir une représentation plus cohérente. Les techniques de filtrage supplémentaires, les algorithmes de morphologie mathématique (comme l'érosion et la dilatation) sont employés pour ces ajustements visuels.

Pour finir, l'interprétation constitue la phase où les résultats des images traitées sont analysés et où des décisions sont prises sur la base des données extraites.

L'organisation de ce mémoire est structurée en quatre chapitres, chacun abordant des aspects clés de la segmentation d'images dans le contexte du diagnostic du pied diabétique. Le chapitre 1 établit le cadre général et les objectifs de l'étude, en introduisant les étapes du traitement d'images, de l'acquisition à l'interprétation, tout en se concentrant sur l'importance de la segmentation des ulcères du pied diabétique. Le chapitre 2 se consacre à la segmentation d'images, en définissant la technique et en présentant ses applications en vision par ordinateur et en médecine, en mettant particulièrement l'accent sur les principales méthodes de segmentation, notamment les approches interactives. Le chapitre 3 explore la classification des pixels, détaillant les différentes approches, y compris les classifications supervisées, non supervisées et semi-supervisées, afin d'identifier efficacement les structures des images. Enfin, le chapitre 4 présente notre approche de segmentation interactive par classification, mettant en avant l'intégration de l'interaction utilisateur dans le processus de segmentation, et détaillant notre méthode en plusieurs étapes allant de l'acquisition d'images à l'obtention d'images segmentées améliorées par post-traitement. Cette structure vise à offrir une compréhension approfondie des techniques de segmentation et leur application clinique dans le domaine du pied diabétique.

1

Contexte et but de ce travail

1.1 Introduction

Ce chapitre établit le cadre général de notre travail et les objectifs de l'étude, offrant ainsi une base fondamentale pour la compréhension des méthodes de segmentation d'images dans le diagnostic du pied diabétique. La première partie de ce chapitre détaille les étapes du traitement d'images, incluant l'acquisition, les pré-traitements, la segmentation et l'interprétation. La seconde partie de ce chapitre se concentre sur le pied diabétique et les images d'ulcères (Diabetic Foot Ulcer, DFU), en analysant les systèmes d'acquisition d'images, l'importance de la segmentation, ainsi que les techniques manuelles et automatiques avec leurs avantages et inconvénients respectifs. De plus, les caractéristiques cliniques, visuelles et texturales des tissus des DFU, y compris les variations de couleur, sont examinées pour leur pertinence diagnostique.

1.2 Traitement d'images

Le traitement d'images est une discipline qui représente l'ensemble des opérations à effectuer sur des images numériques. Il consiste à améliorer la qualité des images en éliminant les bruits, les défauts et renforcer l'information utile.

Le domaine du traitement d'images offre une diversité d'applications, s'étendant à presque tous les secteurs de la science et de la technologie. Voici une brève liste pour illustrer la variété des applications possibles du traitement d'images [9] :

- *Industrie* : contrôles automatisés dans l'industrie alimentaire ou automobile (détection d'obstacles, reconnaissance des panneaux de signalisation, ... etc.).
- *Médecine* : analyse et compréhension des images radiographiques.
- *Divertissement et multimédia* : retouche photo, jeux vidéo, réalité virtuelle.
- *Agriculture* : évaluation de la superficie des terres, évaluation de la qualité des fruits et légumes par inspection visuelle.

Généralités

1. *Image* : c'est une matrice qui est représentée par un ensemble de pixels, en largeur (nombre de colonnes (C)) et en hauteur (nombre de lignes (L)). La figure (1.1) illustre un exemple d'une image numérique.

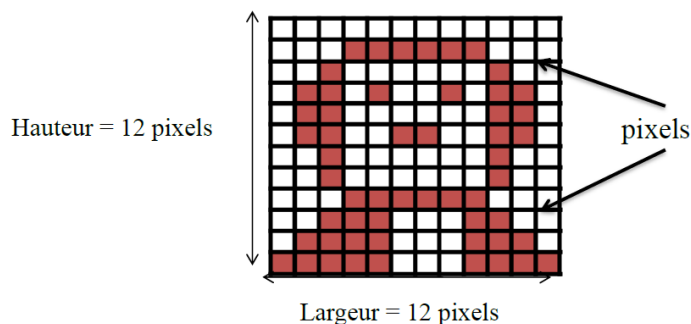


FIGURE 1.1 – Image numérique.

Il existe différents types d'images numériques [9] :

- *Images binaire* : dans une image binaire, chaque pixel est soit noir ou blanc.
 - *Images en niveaux de gris* : elles se basent sur une gradation de nuances de gris dans l'intervalle [0 255].
 - *Images couleurs* : chaque pixel est représenté par trois valeurs (rouge, vert, bleu), sachant que chaque couleur contient 256 nuances.
2. *Pixel* : un pixel représente la plus petite unité d'une image numérique (figure (1.1)). La définition d'un pixel est généralement associée à deux aspects principaux :
- *spatial* : les informations spatiales d'un pixel désignent sa localisation (position) au sein de l'image par rapport aux pixels voisins.
 - *spectral* : les informations spectrales d'un pixel correspondent aux valeurs des canaux de couleur dans le cas d'une image en couleur, ou aux valeurs de bande spectrale (intensité) dans le cas d'une image en niveau de gris.
3. *Région* : est une partie de l'image, représentée par un ensemble connexe de pixels, ayant des propriétés communes (intensité, texture, couleur, taille, forme, ... etc), qui les différencient des pixels des régions voisines (figure (1.2)).




FIGURE 1.2 – Différentes régions de l'image.

4. *Contour* : représente les frontières qui séparent les différentes zones (régions) d'une image (figure (1.3)).




FIGURE 1.3 – Contours : (a) image originale, (b) filtre de Canny, (c) filtre de Roberts.

5. *Histogramme* : l'histogramme représente la répartition des niveaux de gris ou des valeurs de couleur de l'image, cela se matérialise sous forme d'un graphique indiquant

la fréquence d'apparition de chaque valeur de couleur ou de niveaux de gris (voir la figure (1.4)).

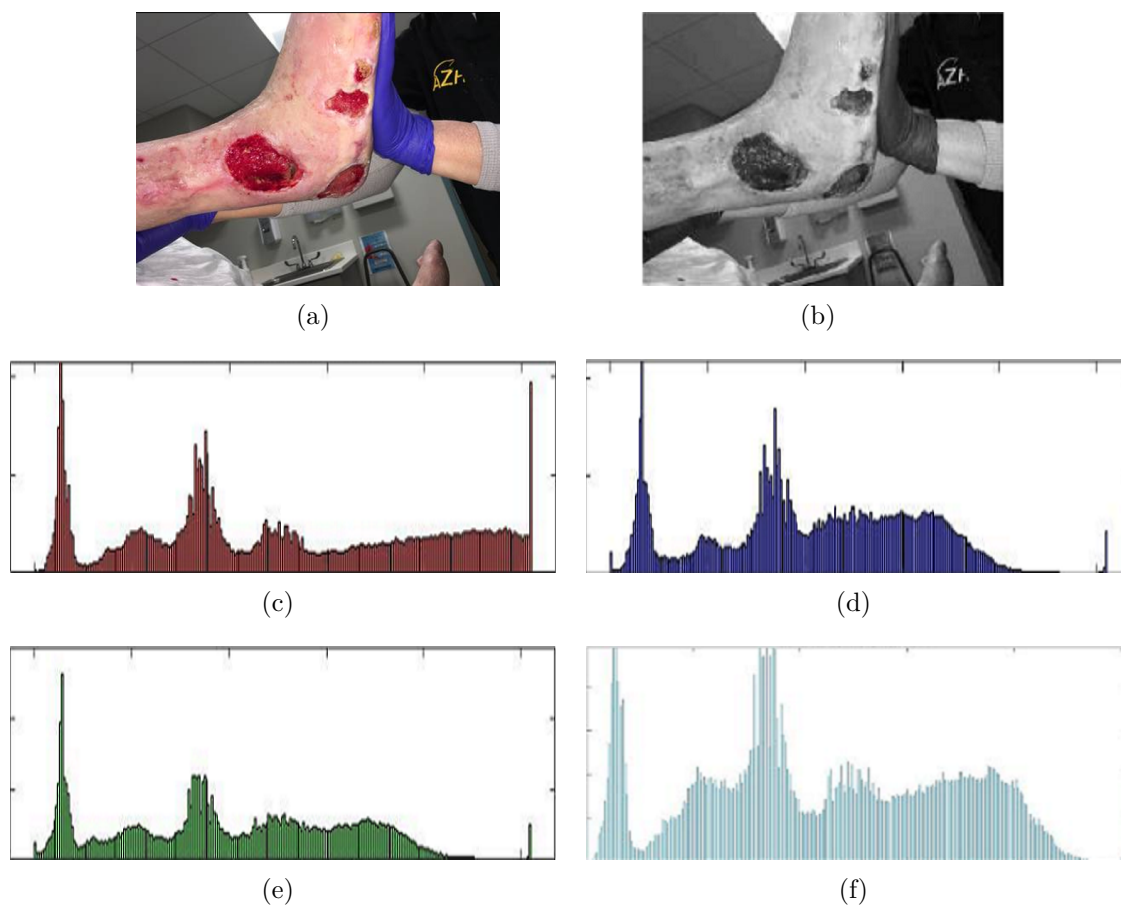


FIGURE 1.4 – Histogramme d'image : (a) image couleur, (b) image niveaux de gris, (c) histogramme sur le canal Rouge, (d) histogramme sur le canal Bleu, (e) histogramme sur le canal Vert, (f) histogramme en niveau de gris.

Dans notre travail, nous nous sommes intéressés à la vision par ordinateur, où nous avons appliqué une chaîne de traitement d'images (figure (1.5)), sur des images issues du domaine médical.




FIGURE 1.5 – Chaîne de traitement d'images.

1.2.1 Acquisition d'image

L'acquisition est la première étape du processus de traitement d'images. C'est à travers elle que les données visuelles sont capturées.

Plusieurs types de caméras d'acquisition sont utilisées, chacune avec ses propres caractéristiques et applications spécifiques. Parmi elles on peut citer : les appareils photos numériques, les scanners, les caméras thermiques, les caméras de sécurité et de surveillance, les caméras médicales spécialisées, les microscopes numériques . . . etc.

Des exemples de caméras d'acquisition sont montrés dans la figure (1.11) :



FIGURE 1.6 – Système d'acquisition d'images : (a) appareil photo numérique, (b) appareil thermique, (c) caméra de surveillance, (d) microscope numérique.

1.2.2 Pré-traitement

Le pré-traitement constitue la phase précédant le traitement principal de l'image. L'objectif est d'éliminer les bruits et les défauts obtenus lors de l'acquisition. Cette étape permet d'améliorer la qualité des images acquises et les rendre plus appropriées pour les étapes en aval [9]. Il existe plusieurs pré-traitement, parmi eux [10] :

1. Amélioration du contraste

L'amélioration du contraste dans le traitement d'images vise à accroître la différence perceptuelle entre les niveaux de luminosité des pixels. Cette technique permet de rendre les détails plus visibles, améliorant ainsi la qualité de l'image pour une analyse plus précise. En ajustant le contraste, on cherche à rendre les objets plus distincts en augmentant la variation entre les régions claires et sombres d'une image (voir la figure (1.7)).



FIGURE 1.7 – Amélioration du contraste : (a) image originale, (b) image améliorée avec un faible ajustement (c) image améliorée avec un ajustement élevé.

2. Binarisation

Le principe de la binarisation consiste à convertir une image en niveaux de gris ou en couleur en une image binaire. Pour ce faire, on applique un seuillage : si la valeur d'un pixel est inférieure au seuil, il prend la valeur 0. Si elle est égale ou supérieure au seuil, il prend la valeur 1. La figure (1.8) illustre un exemple du processus de binarisation appliqué sur une image couleur après conversion en niveau de gris.



FIGURE 1.8 – Binarisation : (a) image couleur, (b) image en niveau de gris, (c) image binaire.

3. Filtrage

Le filtrage est une opération qui permet de supprimer le bruit de l'image. Plusieurs types de filtrage existent et parmi eux, on peut citer :

- *Filtre gaussien* : Ce filtre est une convolution avec un noyau basé sur la fonction gaussienne, définie comme suit :

$$f(x, y) = \frac{1}{2\pi\sigma^2} \exp\left(-\frac{x^2 + y^2}{2\sigma^2}\right) \quad (1.1)$$

σ est l'écart-type qui représente la taille du noyau gaussien. Plus cet écart-type est élevé, plus le noyau sera large, ce qui se traduit par un effet de flou plus important dans l'image filtrée. L'application du filtre gaussien permet de rendre l'image plus lisse.

- *Filtre moyen* : Appelé aussi moyenneur, est le filtre le plus simple. Il calcule la moyenne des valeurs des pixels voisins dans une région spécifique, ce qui diminue

le bruit mais peut également entraîner un lissage des contours et des détails fins de l'image.

- *filtre médian* : Ce filtre permet de remplacer chaque pixel par la médiane des pixels voisins, ce qui entraîne une amélioration de la clarté visuelle en diminuant le bruit tout en maintenant les caractéristiques essentielles de l'image.

La figure (1.9) illustre un exemple d'application des filtres (gaussien, moyen, et médian) sur une image couleur.

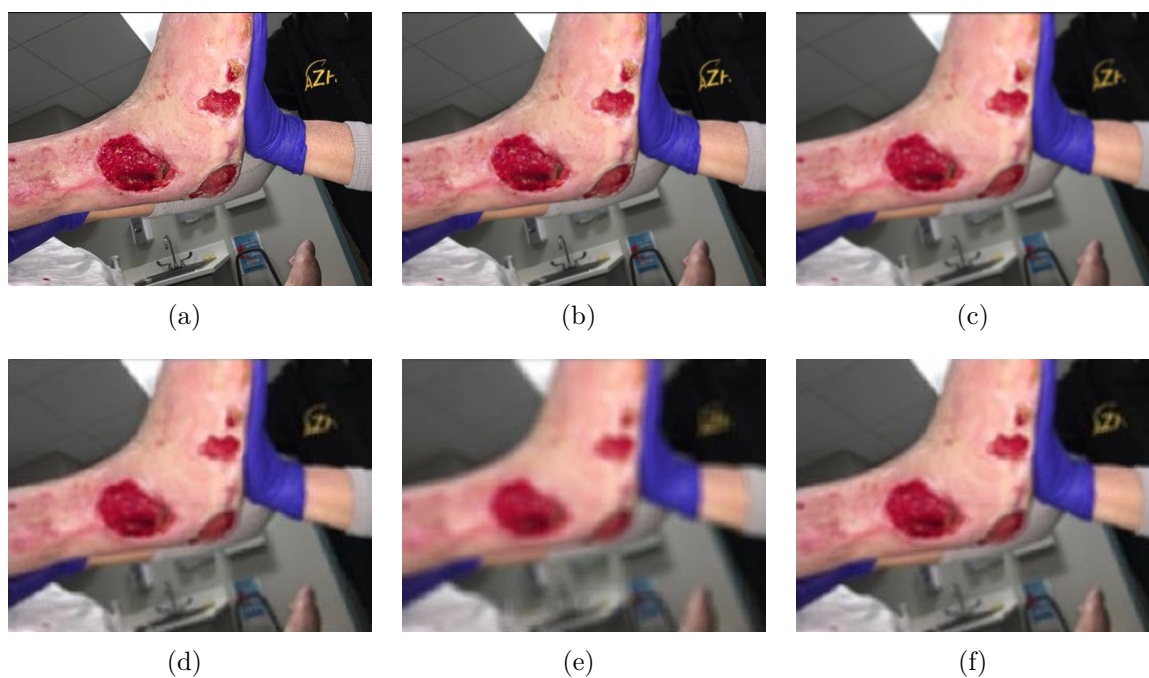


FIGURE 1.9 – Filtrage d'image : (a) image originale, (b) filtre gaussien [$\sigma = 1$], (c) filtre gaussien [$\sigma = 2$], (d) et (e) filtre moyenneur, (f) filtre médian.

1.2.3 Segmentation

La segmentation consiste à partitionner l'image en plusieurs régions connexes (figure (1.2)), suivant des critères d'homogénéités qui peuvent être spatiaux (position, forme ...etc) ou spectraux (l'intensité, couleur ...etc).




FIGURE 1.10 – Segmentation d’une image couleur : (a) image originale, (b) image segmentée par k-means (en deux régions), (c) image segmentée par k-means (en trois régions).

1.2.4 Post-traitement

Le post-traitement inclut diverses techniques visant à améliorer la segmentation des images. Parmi ces techniques, on trouve les opérations de morphologie mathématique :

1. *Ouverture morphologique* : Cette opération consiste en une érosion suivie d’une dilatation de l’image à l’aide du même élément structurant. Elle permet de supprimer les petites imperfections tout en préservant la forme générale des objets.
2. *Fermeture morphologique* : Inverse de l’ouverture, cette opération applique une dilatation suivie d’une érosion avec le même élément structurant. Elle est utile pour combler les petits trous ou les espaces à l’intérieur des objets segmentés.
3. *Imfill* : Cette technique utilise un algorithme basé sur la reconstruction morphologique. Lors de son application, elle comble les régions internes, sélectionnant souvent la plus grande zone connectée, ce qui permet d’améliorer la cohérence de la segmentation.




FIGURE 1.11 – (a) vérité terrain, (b) image segmentée, (c) ouverture, (d) fermeture.

L’érosion et la dilatation binaire représentent les deux opérations de base de la morphologie mathématique, sont souvent utilisées en conjonction pour améliorer la segmentation.

1.2.5 Interprétation

L’interprétation implique l’analyse des régions segmentées pour extraire des informations significatives. Cela peut inclure :

- Identification des objets ou des structures présentes dans chaque région.

- Classification des régions en fonction de leur contenu.
- Analyse des relations spatiales entre les différentes régions segmentées.

Le traitement d'image est essentiel pour diagnostiquer et gérer les maladies chroniques. Dans le cadre de notre recherche, nous nous concentrons sur les ulcères du pied diabétique (DFU). Grâce aux techniques de traitement d'image, il est possible de détecter, surveiller et évaluer ces ulcères avec une précision remarquable, ce qui aide à éviter des complications sévères. Cette application permet d'améliorer considérablement les soins des patients diabétiques, en offrant des diagnostics précoces et des traitements plus efficaces.

Dans ce qui suit, nous allons présenter brièvement quelques notions sur le diabète, le pied diabétique, le système d'acquisition des images, ainsi que les techniques de segmentation des images DFU et les caractéristiques des tissus des DFU.

1.3 Diabète

Le diabète sucré ou le diabète, est une maladie chronique causée par un taux élevé du glucose dans le sang [1] [hyperglycémie] (le glucose est une source d'énergie essentielle pour le corps humain) Les cellules pancréatiques sécrètent de l'insuline, qui transfère le sucre du sang vers les cellules du corps, où il est stocké ou utilisé comme énergie. Cependant, chez une personne diabétique, soit le pancréas ne peut pas produire suffisamment d'insuline, soit le corps perd sa capacité à utiliser l'insuline produite [1].

Le diabète est l'une des maladies les plus répandues dans le monde (Près de 463 millions de personnes sont atteintes de diabète dans le monde) [11]. Au cours de son évolution, le diabète peut engendrer de graves complications touchant le cœur, les vaisseaux, les yeux, les reins et les nerfs. Il est important pour les personnes atteintes de diabète de gérer leur maladie de manière correcte pour prévenir les complications à long terme en suivant un traitement varié en fonction du type de diabète et peut inclure des médicaments y compris l'insuline, une alimentation équilibrée, l'exercice physique, et dans certains cas des interventions chirurgicales. La figure (1.12) expose les principales complications associées au diabète. Ce travail s'est spécifiquement concentré sur les complications du pied diabétique résultant de l'atteinte des vaisseaux sanguins et des nerfs périphériques.

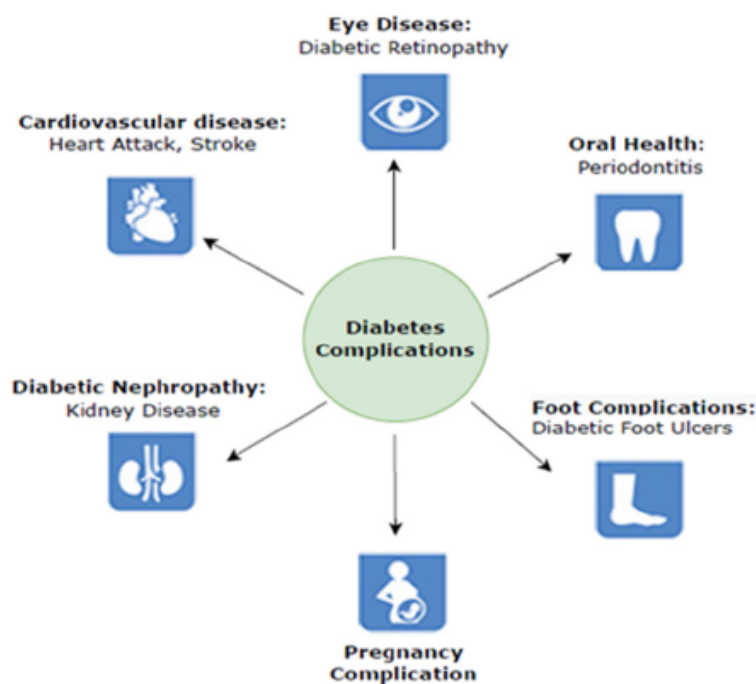


FIGURE 1.12 – Complications du diabète [1].

Il existe différents types de diabète, notamment le type 1, type 2 et le diabète gestationnel.

- Le diabète de type 1 est caractérisé par une destruction auto-immune des cellules bêta du pancréas, qui sont responsables de la production d’insuline [12]. Cette destruction entraîne une production insuffisante ou nulle d’insuline, ce qui se traduit par une hyperglycémie (taux élevé de glucose dans le sang). Les symptômes typiques incluent une soif excessive, une perte de poids inexplicée, une fatigue et une vision floue. Les personnes atteintes de ce type de diabète doivent prendre de l’insuline régulièrement pour réguler leur taux de sucre dans le sang. Le suivi médical, la gestion de l’alimentation et l’exercice physique sont essentiels dans la gestion du diabète de type 1.
- Le diabète de type 2 est caractérisé par une résistance à l’insuline et une production insuffisante d’insuline par le pancréas. Il est souvent lié à des facteurs tels que l’obésité, le manque d’activité physique et les antécédents familiaux de diabète. Les symptômes incluent une soif excessive, une envie fréquente d’uriner, une fatigue persistante, une vision floue, une cicatrisation lente des plaies, des infections fréquentes, et une sensation de faim constante même après avoir mangé. La gestion du diabète de type 2 implique généralement des changements de mode de vie, tels que l’alimentation équilibrée, l’exercice régulier, et dans certains cas des médicaments. Un suivi médical régulier est crucial pour surveiller et contrôler la maladie.
- Diabète gestationnel est un autre type de diabète qui intervient pendant la grossesse, il peut causer des complications pour la mère et le bébé. Au cours du diabète gestationnel, le taux de césarienne est plus élevé.

1.4 Pied diabétique

Le pied diabétique représenté dans la figure (1.13), est l'une des complications majeures du diabète. Cela peut entraîner des lésions nerveuses et des problèmes de circulation sanguine dans les pieds, augmentant ainsi le risque d'infections graves, d'ulcères et même pouvant conduire à l'amputation du pied ou du membre s'ils ne sont pas traités correctement [13,14]. Il est essentiel pour les personnes atteintes du diabète de prendre soin de leurs pieds, de contrôler leur glycémie et de consulter régulièrement leur médecin pour prévenir les complications du pied diabétique.



FIGURE 1.13 – Illustration d'ulcère du pied.

Le diagnostic d'un pied diabétique implique la détection de lésions, qui peuvent entraîner des complications graves pour les patients diabétiques.

- *La neuropathie diabétique* se caractérise par des douleurs brûlantes aux extrémités, une altération de la sensibilité à la chaleur, ainsi que des déformations du pied et une peau sèche [15]. Le diagnostic de la neuropathie implique généralement un examen clinique pour évaluer les symptômes et des tests supplémentaires tels que le test de sensibilité, test de vitesse de conduction nerveuse pour évaluer la fonction nerveuse ... etc. Un exemple de la neuropathie illustré dans la figure (1.14).



FIGURE 1.14 – Diagnostic de la neuropathie diabétique.

- *L'arthériopathie diabétique* est une complication du diabète caractérisée par un rétrécissement ou un blocage des artères situées principalement dans les jambes. Cela peut entraîner une diminution du flux sanguin vers les jambes et les pieds, augmentant ainsi le risque de complications grave telles que l'ulcération des pieds. Différents types de tests peuvent être réalisés permettant de faire le diagnostic d'arthériopathie. Il se différencie en tests réalisés au repos et en tests réalisés à l'exercice ou après l'exercice [16]. Un exemple de l'arthériopathie illustré dans la figure (1.15).



FIGURE 1.15 – Diagnostic de l'arthériopathie diabétique.

- *L'infection du pied diabétique* est un problème courant, associé à une morbidité élevée et à des coûts importants pour la santé publique. Elle peut affecter les tissus mous, les articulations, ou les os en cas de chronicisation de la plaie. Les infections peuvent être causés des bactéries, des virus, des champignons ... etc. Un exemple de l'infection illustré dans la figure (1.16).



FIGURE 1.16 – Pieds diabétiques infectés : cercle en rouge entoure l’infection.

Le diagnostique de l’infection du pied diabétique est généralement basé sur le résultat d’un ensemble d’examens, notamment [17] :

- *Examens cliniques* :
l’examen clinique implique l’observation visuelle du pied afin de repérer les signes de l’infection tels que la rougeur, la sensation de chaleur, le gonflement, des ulcères ou des changements de la couleur de la peau.
- *Examens biologiques* :
l’examen biologique implique l’examen d’échantillons comme le sang ou les prélèvements de plaies afin de repérer les indicateurs d’infection tels que les marqueurs inflammatoires ou la présence d’organismes infectieux.
- *Examens iconographiques (tests d’imagerie)* :
l’évaluation par imagerie médicale débute par la réalisation de radiographies standard, d’échographies ou d’IRM, permettant d’évaluer l’étendue de l’infection et de dépister la présence éventuelle d’ostéomyélite (infection osseuse).

La prise en charge du pied diabétique nécessite une équipe multidisciplinaire, Son rôle est de répondre aux problèmes suivants : diagnostic précoce et bilan étiologique des ulcérations, indications thérapeutiques médicales ou chirurgicales, traitement de l’infection, optimisation de l’équilibre du diabète, soins locaux, éducation à la décharge des plaies, prévention des récurrences [18].

Notre analyse se concentrera sur l’utilisation de tests d’imagerie pour les ulcères du pied diabétique (DFU). En employant des technologies avancées telles que la photographie numérique, nous pourrions obtenir des images détaillées des tissus affectés. Cela permettra de visualiser les structures internes, d’évaluer la profondeur des ulcères.

1.5 Systèmes d’acquisition des images DFU

Les systèmes d’acquisition d’images pour DFU capturent des images numériques de la surface du pied. Pour standardiser la collecte de données des DFU, plusieurs équipes de recherche ont proposé des solutions innovantes. Par exemple, Wang et al [19] ont développé une application smartphone capable de segmenter les images des plaies DFU, ainsi qu’un boîtier de capture d’images pour améliorer l’acquisition des images, encourageant ainsi l’auto-surveillance des patients. De même, Yap et al [20] ont créé l’application

mobile FootSnap pour standardiser la capture photographique de l'aspect plantaire des pieds, utilisée dans des essais cliniques pour la prévention des DFU. D'autres avancées comprennent un dispositif de "selfie du pied" pour positionner le pied devant un smartphone sans contact avec la surface, ainsi que des systèmes automatisés de détection de DFU utilisant des technologies mobiles et basées sur le cloud. La figure (1.17) représente quelques exemples d'appareils d'acquisitions des images DFU.




FIGURE 1.17 – Illustration des appareils d'acquisitions : (a) Caméra thermique, (b) Selfie des pieds, (c) Podiscan, (d) FootSnap.

1.6 Segmentation des images DFU

La segmentation d'images DFU permet de diviser l'image en régions distinctes, ce qui simplifie le processus d'analyse en se concentrant spécifiquement sur la région de l'ulcère. Cela permet de détecter les changements dans la taille, la forme et la profondeur de l'ulcère, fournissant ainsi des informations cruciales pour évaluer la progression de la maladie et l'efficacité des traitements. Il existent deux types de techniques de segmentation des images DFU [21] :

1.6.1 Segmentation manuelle

La segmentation manuelle des images DFU est une pratique essentielle dans le domaine médical, notamment pour évaluer la profondeur, la gravité et les types de tissus des ulcères, ainsi que pour faciliter le suivi de l'évolution des lésions. Cette technique offre l'avantage de fournir une précision élevée dans l'analyse des images. Cependant, elle peut être très longue et nécessite un savoir-faire important, cela peut entraîner une réduction de son efficacité dans les environnements cliniques où la charge de travail est élevée. Voici quelques-uns des logiciels couramment utilisés pour effectuer une segmentation manuelle :

GIMP : est un éditeur d'images gratuit et open-source qui propose également des outils de segmentation pour délimiter manuellement les ulcères dans les images DFU.

Photo-shop : est un logiciel de traitement d'images et de dessin assisté par ordinateur permettant de créer et d'améliorer une grande diversité de projets visuels.

Photo-filtre : est un logiciel de retouche d'image créé par Antonio Da Cruz. Outre les traitements classiques de l'image (recadrage, contraste, gamma, etc), d'un certain nombre de filtres pour améliorer et transformer des photos numériques (brushs, textures, incrustations, ...).

1.6.2 Segmentation automatique

La segmentation automatique des images DFU utilise des algorithmes informatiques (machine learning et deep learning) [22]. Les méthodes couramment utilisées pour cette segmentation comprennent les réseaux de neurones convolutifs, les contours actifs, les méthodes de segmentation par régions et la segmentation par classification. Cependant, la segmentation automatique présente aussi ses limites. Elle peut manquer de précision par rapport à la segmentation manuelle, notamment lorsque les ulcères ont des contours flous ou des variations de luminosité importantes.

1.7 Caractéristiques des tissus des DFU

Les DFU présentent différentes caractéristiques cliniques, visuelles et texturales en fonction de leur stade.

- *Les caractéristiques cliniques* : font référence aux signes et aux symptômes détectés lors de l'évaluation médicale d'un patient.
- *Les caractéristiques visuelles* : font référence aux éléments observables lors de l'inspection visuelle d'un patient.
- *Les caractéristiques texturales* : concernent les attributs de texture de la peau.

Parmi les caractéristiques les plus importantes en vision par ordinateur, on trouve :

1. **La couleur** : elle peut varier en fonction de différents facteurs (figure 4.1).
 - La couleur noire indique la présence de nécrose (tissu mort). La nécrose est souvent associée à une couleur foncée, car elle résulte de l'irrigation sanguine insuffisante dans la région affectée.
 - La couleur rouge indique la granulation et la cicatrisation. La granulation se produit lorsque de nouveaux petits vaisseaux sanguins et du tissu de cicatrisation commencent à se former dans une plaie en guérison.
 - La couleur blanche indique la présence de tissu cicatriciel, qui est une étape de la guérison où le tissu se régénère pour remplacer celui qui a été perdu ou endommagé.
 - La couleur jaune indique une spéticémie (présence d'exsudat), qui est un liquide composé de fluides corporels, de cellules mortes. L'exsudat peut indiquer une infection ou une inflammation dans la région affectée.



FIGURE 1.18 – Couleur de l'ulcère.

2. **La taille** : Les DFU peuvent présenter une gamme de tailles, allant de petites plaies à de larges ulcérations (figure (1.19)).



FIGURE 1.19 – Taille de l'ulcère.

3. **La profondeur** : La profondeur des DFU peut être variable (plus la profondeur de l'ulcère est grande, plus les caractéristiques des tissus présentent des plaies plus infectées) (figure (1.20)).



FIGURE 1.20 – Profondeur d'un ulcère.

4. **La gravité** : La gravité peut être évaluée en fonction de divers facteurs tels que la profondeur, la présence d'infection ... etc (figure 1.21).



FIGURE 1.21 – Gravité d'un ulcère.

5. **Texture de la peau** : La peau environnante de la plaie peut afficher des caractéristiques telles que la sécheresse, les fissures, gonflement ... etc (figure (1.22)).



FIGURE 1.22 – Textures de la peau.

6. **Texture de l'ulcère** : L'aspect de l'ulcère varie en fonction de son stade et de sa cause : il peut présenter une texture rugueuse, des contours irréguliers, voire être recouvert de tissu fibrineux (voir la figure (1.23)).



FIGURE 1.23 – Différentes textures de l'ulcère.

7. **Inflammation** : Les signes d'inflammation peuvent être observés tels que rougeur, chaleur, gonflement (figure (1.24)).



FIGURE 1.24 – Inflammation des ulcères.

8. **Odeur** : Certains DFU peuvent dégager une odeur désagréable, surtout lorsqu'ils sont infectés.

1.8 Conclusion

Pour conclure, le traitement des images de plaies des (DFU) est une étape cruciale dans la gestion des complications liées au diabète. Le diabète peut entraîner des ulcérations

graves aux pieds, augmentant le risque d'infections et d'amputations si elles ne sont pas traitées rapidement. Afin d'optimiser la détection de ces ulcères, un pré-traitement des images est nécessaire, notamment à travers des techniques de rehaussement de contraste et de filtrage de bruit. Ces techniques permettent d'améliorer la qualité des images, facilitant ainsi la segmentation, qui est essentielle pour identifier avec précision les régions affectées.

Dans ce contexte, la segmentation d'images, y compris par des méthodes telles que le seuillage, permet de délimiter les régions touchées par les ulcères. Ce processus est fondamental pour orienter le diagnostic et les décisions cliniques.

Dans le chapitre suivant, nous explorerons la segmentation d'images interactive, une approche avancée qui permet aux experts de collaborer directement avec les algorithmes de segmentation, en affinant les résultats de manière itérative pour une meilleure précision. Cette méthode promet d'améliorer considérablement les résultats dans le traitement des DFU.

2

SEGMENTATION D'IMAGES COULEUR INTERACTIVE

2.1 Introduction

Dans ce chapitre, nous allons explorer la segmentation d'images. Celle-ci vise à diviser une image en différentes régions homogènes afin de faciliter leur analyse. Nous commencerons par définir cette technique et explorerons ses applications variées, notamment en vision par ordinateur et en médecine. Nous aborderons les principales méthodes de segmentation, telles que la segmentation par contour, par région et par classification, ainsi que l'extraction d'attributs couleur et texture. Nous mettrons un accent particulier sur les techniques de segmentation interactive.

2.2 Segmentation d'images

La segmentation d'images est l'une des opérations les plus importantes de traitement d'image, son principe est de partitionner une image en plusieurs régions homogènes [23]. Une région homogène est définie comme étant un ensemble connexe de pixels ayant des propriétés communes (intensité, texture, couleur, ...) suivant des critères d'homogénéités [23]. La figure (2.1) illustre un exemple de segmentation d'une image couleur issue du domaine médical.




FIGURE 2.1 – Segmentation d'image couleur : (a) image originale, (b) vérité terrain, (c) image segmentée par K-means.

La segmentation d'images est un domaine actif en vision par ordinateur. Plusieurs méthodes de segmentation d'images couleur sont proposées dans la littérature [6]. Parmi elles, on peut citer [24] : la segmentation par seuillage d'histogrammes, la segmentation par classification de pixels, la segmentation par morphologie mathématique ... etc. Ces méthodes sont utilisées dans divers domaines tels que [25] :

- Microscopie cellulaire,
- Vision industrielle,
- Reconnaissance faciale,
- Reconnaissance d'empreintes digitales,
- Imagerie médicale et bien d'autres domaines qui méritent une étude approfondie [25].

Formellement, la segmentation d'une image A en régions R_i , $i = 1 \dots n$, est définie par les propriétés suivantes [26] :

$$A = \bigcup_i^n R_i \quad (2.1)$$

$$\forall i = 1 \dots n \ R_i \neq \phi \quad (2.2)$$

$$\forall i, j ; i \neq j \ R_i \cap R_j = \phi \quad (2.3)$$

$$\forall i, i = \overline{1, n} \ P(R_i) = \text{vrai} \quad (2.4)$$

$$\forall i, j \ i = \overline{1, n} \ P(R_i \cup R_j) = \text{faux} \quad (2.5)$$

Où :

- R_i et R_j sont deux régions voisines.
 - P est un prédicat d'homogénéité.
 - n représente le nombre de régions.
1. La première condition implique que chaque pixel de l'image soit attribué à une région spécifique, notée R_i , et que lorsque toutes ces régions sont réunies, elles couvrent l'image entière.
 2. La deuxième condition signifie que pour chaque élément i de 1 à n , la région R_i contient au moins un élément (R_i n'est pas un ensemble vide).
 3. La troisième condition précise que deux régions distinctes doivent être disjointes.
 4. La quatrième condition exprime que chaque région doit satisfaire un critère d'uniformité (d'homogénéité).
 5. La cinquième condition indique que si deux régions adjacentes (voisines) ne satisfont pas ce même critère.

2.3 Méthodes de segmentation d'images

Les méthodes de segmentation d'images couleur, peuvent être classées en trois grandes catégories [24] : les méthodes basées sur les contours, les méthodes basées sur les régions, et les méthodes basées sur la classification des pixels.

2.3.1 Méthodes basées sur les contours

La segmentation basée sur les contours consiste à trouver les contours des objets (ou des régions) dans une image. Elle est basée sur la détection des changements d'intensité dans le cas des images en niveaux de gris ou de couleur dans le cas des images couleur. Les méthodes de détection de contour populaires incluent la segmentation par l'application du filtre de Canny, Prewitt, Roberts, Sobel, Gaussien, contour actif, ... etc [27]. Ces méthodes de segmentation même si elles représentent plusieurs avantages : simples et rapides et elles donnent une meilleure détection des régions avec des frontières nettes, mais elles sont sensibles aux bruit et aux valeurs d'éclairage et elles trouvent des difficultés de détection des contours pour les régions avec des contours fins.

Un contour peut être défini par trois modèles distincts [28] (voir la figure (2.2)) :

- *Marche d'escalier* : si le contour est net, la marche d'escalier (Figure 2.2 (a)) représente un modèle optimal où le contour est constitué d'une série de pixels reliés perpendiculairement aux variations des niveaux de gris (Gonzalez et Woods, 2002) [28].
- *Rampe* : si le contour est flou, le modèle rampe représente une transition douce dans une image, où le contour est formé par une pente continue de pixels, indiquant une variation graduelle des niveaux de gris (Figure 2.2 (b)).
- *Toit* : s'il s'agit d'une ligne sur un fond uniforme. Ce modèle de contour est utilisé lorsqu'une ligne est superposée à une région de pixels homogènes, et il se caractérise par deux rampes adjacentes ayant des pentes opposées (Figure 2.2 (c)).




FIGURE 2.2 – Différents modèles de contour : (a) marche d'escalier, (b) rampe, (c) toit.

La figure (2.3) montre des exemples de segmentation d'images par approche contours.




FIGURE 2.3 – Segmentation par contours : (a) image originale, (b) image en niveaux de gris, (c) contour actif, (d) Prewitt, (e) Sobel.

2.3.2 Méthodes basées sur les régions

La segmentation d'images basée sur les régions consiste à créer des régions qui facilitent l'identification des différentes parties de l'image [27]. Parmi les méthodes couramment utilisées en segmentation d'images basées sur les régions, on trouve [24] :

A.Méthodes par fusion de régions

Les techniques de fusion de régions (croissance de régions [24] ou division de régions [24]) consistent à fusionner progressivement des pixels ou des régions adjacentes jusqu'à l'obtention d'une segmentation finale, en se basant sur des critères d'homogénéités.

B.Méthodes par division des régions

Les méthodes de segmentation par division de régions consistent à diviser les régions initiales en régions de plus en plus petites jusqu'à ce qu'elles présentent une homogénéité satisfaisante (figure 2.4). Dans ce type de méthodes, l'algorithme s'arrête lorsque toutes les régions obtenues répondent à un certain critère d'homogénéité. Si ce critère n'est pas satisfait, l'image est divisée en zones et chaque zone est soumise à des tests et à une division répétée jusqu'à ce que le critère soit validé. Le processus prend fin lorsque toutes les régions sont homogènes ou que leur taille est inférieure à un seuil minimal prédéfini.

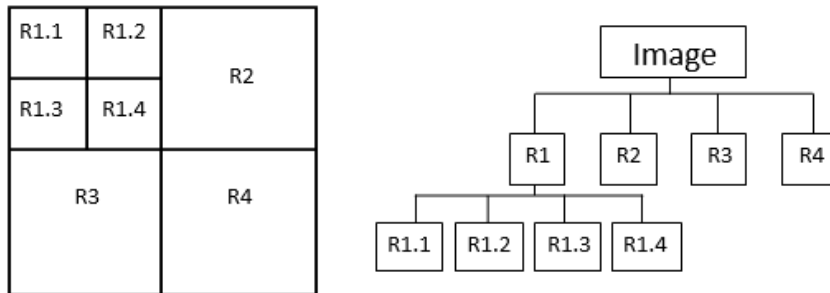


FIGURE 2.4 – Méthode de division de régions.

C. Méthodes par Division / Fusion

Les méthodes de division-fusion suivent un processus itératif où l'image est d'abord divisée puis fusionnée pour obtenir le résultat souhaité. D'abord, diviser l'image en petites régions similaires, puis fusionner les régions voisins similaires. Horowitz et Pavlidis ont été les premiers à proposer cette méthode, qui a ensuite donné lieu à d'autres variantes [29]. Le processus fonctionne comme ceci : chaque région de l'image est examinée pour décider si elle doit être divisée en régions plus petites. Ce processus se répète jusqu'à ce que chaque petite région soit assez homogène. Ensuite, lorsque les régions similaires sont trouvées, elles sont regroupées en une classe. Ce processus de fusion continue tant que les classes répondent au critère d'homogénéité. Lorsqu'on ne peut plus fusionner, on examine les régions adjacents qui n'étaient pas à la même étape de division et on les fusionnes si elles sont suffisamment similaires.

Ces méthodes malgré qu'elles sont simples et efficaces, robuste aux bruit et aux variations d'éclairage, mais elles sont moins précise (régions complexes) et la segmentation peut entraîner des coûts de traitement plus élevés.

D. Méthodes par seuillage

Les méthodes par seuillage consistent à choisir un seuil qui sépare les pixels de l'image en deux catégories distinctes [30] (figure (2.5)). Bien qu'elles sont simples et efficaces, ces méthodes présentent des limitations : elles fonctionnent principalement sur des images avec peu de bruit [27]. Une variété de méthodes de seuillage sont disponibles, comprenant le seuillage global (ou binaire), le seuillage adaptatif, et bien d'autres encore [30]. Parmi les méthodes basées sur le seuillage d'histogrammes, on trouve la méthode d'Otsu [31].



FIGURE 2.5 – Segmentation par seuillage : (a) image couleur, (b) image en niveau de gris, (c) image segmentée avec un seuil=0.5.

2.3.3 Méthodes basées sur la classification des pixels

Les méthodes de cette approche reposent sur la classification de chaque pixel de l'image en une classe prédéfinie. Plusieurs méthodes de segmentation par classification sont disponibles, parmi elles, on peut citer : K-means [32], Fuzzy C-means [33], DBSCAN [34], classification hiérarchique [35], classification spectrale . . . etc. Ces méthodes diffèrent selon la mesure de la distance utilisée entre les pixels, et l'évaluation de la qualité de la classification et de la stratégie de regroupement. Elles facilitent l'interprétation des résultats, mais elles sont sensibles au bruit et ont des difficultés à gérer les frontières floues.

La segmentation d'images repose souvent sur l'analyse des attributs pour diviser une image en régions. Les attributs permettent de caractériser ces régions en fonction de diverses propriétés telles que la couleur, la texture, la forme, . . . etc.

2.4 Extraction des attributs

L'extraction d'attributs est un processus fondamental dans le domaine du traitement d'images et surtout dans l'analyse des images médicales. Son objectif principal est de créer une représentation ou une signature pour chaque image. Elle implique souvent la sélection

et la représentation des caractéristiques visuelles pertinentes dans une image, telles que la couleur, la texture, la forme ... etc [23].

2.4.1 Couleur

En segmentation d'images couleur, la couleur est définie comme l'une des caractéristiques visuelles la plus utilisée pour identifier et délimiter les régions d'intérêt. Elle peut être mesurée dans différents espaces colorimétriques tels que [5] : RVB, TSL, HSV, LUV, HSL, XYZ, YIQ, CMYK, Lab, YCbCr ... etc. La figure (2.6) illustre le domaine du visible représenté dans un spectre électromagnétique (spectre des couleurs).




FIGURE 2.6 – Spectre des couleurs [2].

Afin de simplifier la compréhension de la diversité des nombreux espaces de couleur existants, Nicolas Vandenbroucke a suggéré de les classer en quatre catégories (les systèmes de primaires, les systèmes de luminance-chrominance, les systèmes de perceptuels, et les systèmes d'axes indépendants) [2, 3]. La figure (2.7) représente les quatre familles des espaces de couleur par des rectangles bleus et les sous-familles par des rectangles en pointillés. En générale, les images en couleur sont capturées à l'aide de l'espace (RGB) et tous les autres espaces colorimétriques sont définis par des transformations de cet espace. La figure (2.7) illustre d'où chaque espace colorimétrique est obtenu en suivant les flèches à partir de l'espace (RGB).

Systèmes de primaires

Les systèmes de primaires désignent les ensembles de couleurs de base à partir desquels d'autres espaces colorimétriques peuvent être créés. Les systèmes de primaires réels comprennent RGB, tandis que les systèmes primaires imaginaires (virtuels) incluent XYZ.

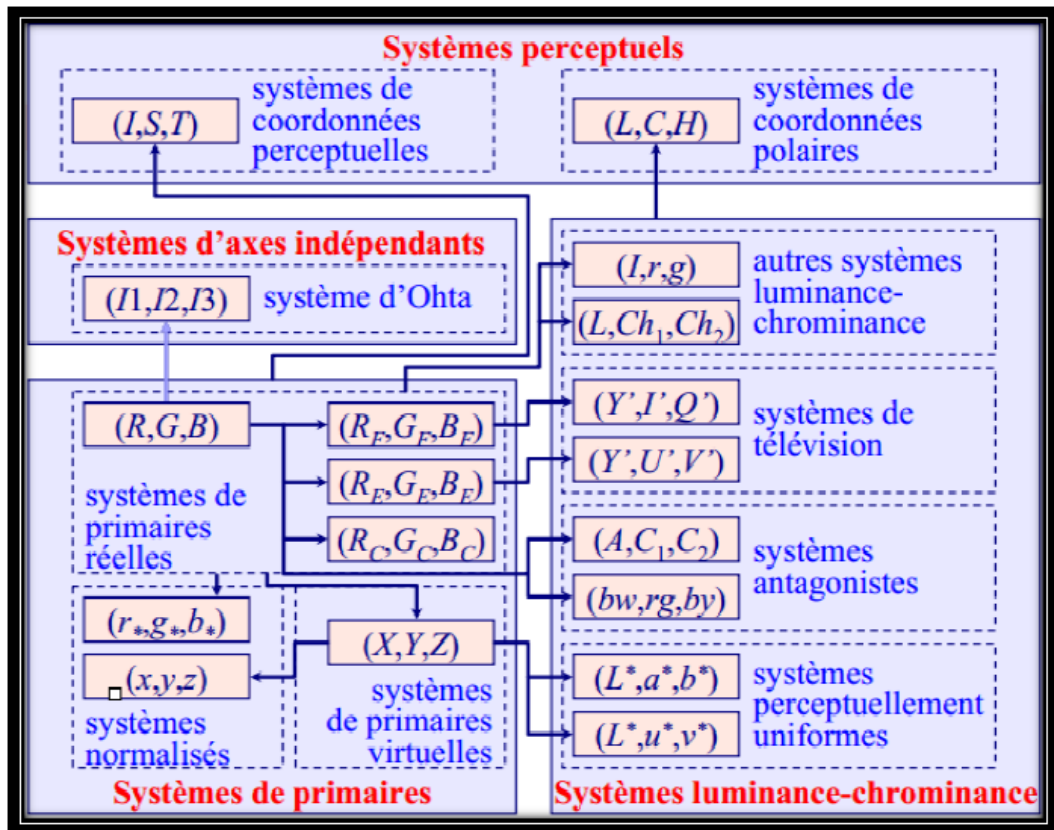


FIGURE 2.7 – Différentes catégories des espaces colorimétriques [3].

Espace RVB : l'espace RVB ou RGB en anglais est défini par la Commission internationale de l'éclairage (CIE) en 1931, représente l'espace le plus répandu en traitement d'image, car la plupart des images sont codées dans ce système, il est basé sur les trois couleurs primaires : rouge, vert et bleu [5]. L'espace RVB est représenté par un cube (figure (2.8)), où les valeurs des composantes Rouge (R), Vert (G), et Bleu (B) varient de 0 à 255.

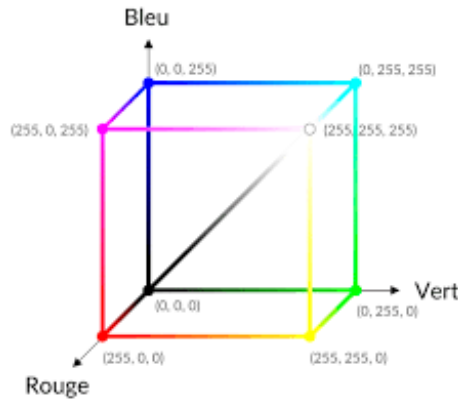


FIGURE 2.8 – Représentation de l'espace RVB.

Espace XYZ : l'espace de couleur XYZ a été introduit en 1931 par la CIE. Il est représenté par une combinaison positive de trois composantes couleurs Y qui représente la luminance, et (X et Z) qui sont combinées pour former toutes les autres couleurs visibles par l'œil humain. Le passage de l'espace RVB à l'espace XYZ est donné par les équations suivantes [36] :

$$X = 0.618 R + 0.177 V + 0.205 B \quad (2.6)$$

$$Y = 0.299 R + 0.587 V + 0.114 B \quad (2.7)$$

$$Z = 0.000 R + 0.056 V + 0.944 B \quad (2.8)$$

Systèmes de luminance-chrominance

Les systèmes de luminance-chrominance sont dérivés à partir d'une composante de couleur représentant la luminance et de deux composantes de couleur représentant la chrominance [2,3]. Parmi ces espaces, on trouve :

Espace Lab : c'est un espace de couleur très utilisé dans divers domaines en raison de sa capacité à représenter toutes les couleurs du visible. Dans cet espace, la couleur est exprimée en trois valeurs principales [4], à savoir :

- *Luminance L* : mesure la luminosité d'une couleur, elle est exprimée en pourcentage allant du 0% (noir) à 100% (blanc).
- *Composante a* : représente une gamme de couleur allant du vert au rouge, avec des valeurs qui varient de -100 à +100.
- *Composante b* : représente une autre gamme de couleur allant du bleu au jaune, avec des valeurs qui varient de -100 à +100.

La figure (2.9) présente la manière dont les couleurs sont représentées dans l'espace Lab.




FIGURE 2.9 – Présentation de l'espace Lab [4,5].

L'espace Lab est dérivé de l'espace RVB via une conversion passant par l'espace XYZ. Les équations permettant de passer du système XYZ au Lab sont [36] :

$$L = 116 \cdot \left(\frac{Y}{Y_0}\right)^{\frac{1}{3}} - 16 \quad \text{pour} \quad \frac{Y}{Y_0} > 0.008856 \quad (2.9)$$

$$L = 903.3 \cdot \left(\frac{Y}{Y_0}\right) \quad \text{pour} \quad \frac{Y}{Y_0} \leq 0.008856 \quad (2.10)$$

$$a = 500 \cdot \left(f\left(\frac{X}{X_0}\right) - f\left(\frac{Y}{Y_0}\right)\right) \quad (2.11)$$

$$b = 200 \cdot \left(f\left(\frac{Y}{Y_0}\right) - f\left(\frac{Z}{Z_0}\right)\right) \quad (2.12)$$

où (X_0, Y_0, Z_0) sont les coordonnées du blanc de référence, et la fonction f est donnée par [36] :

$$f(t) = \sqrt[3]{t} \quad \text{pour} \quad t > 0.008856 \quad (2.13)$$

$$f(t) = 7.7787 \cdot t + \frac{16}{116} \quad \text{pour} \quad t \leq 0.008856 \quad (2.14)$$

Avec :

t : représente la fonction utilisée pour normaliser chaque composante de l'espace RVB avant de les convertir en XYZ.

f : représente la fonction utilisée dans le calcul des composantes Lab après avoir obtenu les valeur XYZ.

Espace LUV : cet espace a été proposé en 1976 par CIE, c'est un modèle qui est perceptuellement uniforme [4]. L'espace de couleur LUV représenté dans la figure (2.10), utilise trois composants : la luminance (L), la composante rouge-vert (U), et la composante bleu-jaune (V).




FIGURE 2.10 – Représentation de l'espace LUV.

L'espace de couleur LUV permet de représenter les couleur de manière plus proche de la perception humaine. Il a été extrait de l'espace RVB via l'espace XYZ en u. Pour effectuer le passage de l'espace XYZ à l'espace LUV, il suffit d'appliquer les équations suivantes [4] :

$$L = 116 \cdot \left(\frac{Y}{Y_0}\right)^{\frac{1}{3}} - 16 \quad \text{pour} \quad \frac{Y}{Y_0} > 0.008856 \quad (2.15)$$

$$L = 903.3 \cdot \left(\frac{Y}{Y_0}\right) \quad \text{ailleurs} \quad (2.16)$$

$$U = 13L \cdot (U' - U'_0) \quad (2.17)$$

$$V = 13L \cdot (V' - V'_0) \quad (2.18)$$

Avec :

$$U' = \frac{4X}{X + 15Y + 3Z} \quad (2.19)$$

$$V' = \frac{9X}{X + 15Y + 3Z} \quad (2.20)$$

$$U'_0 = \frac{4X_0}{X_0 + 15Y_0 + 3Z_0} \quad (2.21)$$

$$V'_0 = \frac{9X_0}{X_0 + 15Y_0 + 3Z_0} \quad (2.22)$$

où (X_0, Y_0, Z_0) sont les coordonnées d'un blanc de référence dans l'espace XYZ.

Espace YIQ : utilisé principalement dans la télévision analogique, il a été adopté en premier par le NTSC (National Television System Committee) [37]. L'espace de couleur YIQ illustré dans la figure (2.11), sépare la luminance (Y) de la chrominance (IQ).




FIGURE 2.11 – Représentation de l'espace YIQ.

Le passage de l'espace RVB à l'espace YIQ est donné par les formules suivantes :

$$Y = 0.2992 R + 0.5868 V + 0.1140 B \quad (2.23)$$

$$I = 0.5960 R - 0.2742 V - 0.3219 B \quad (2.24)$$

$$Q = 0.2109 R - 0.5229 V + 0.3120 B \quad (2.25)$$

Espace YCbCr : dans l'espace de couleur YCbCr (figure (2.12)), Y représente la luminance, tandis que Cb représente la composante de chrominance bleue et Cr représente la composante de chrominance rouge. Le passage de l'espace RGB à l'espace YCbCr est donné par les équations qui suivent [38] :

$$Y = 0.299 R + 0.587 G + 0.11 B \quad (2.26)$$

$$Cb = (B - Y)/1.772 + 0.5 \quad (2.27)$$

$$Cr = (R - Y)/1.402 + 0.5 \quad (2.28)$$

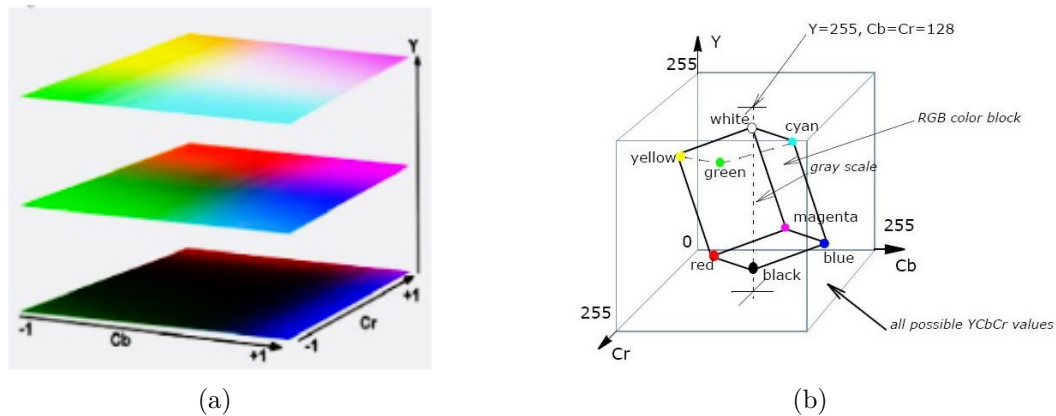


FIGURE 2.12 – Représentation de l'espace YCbCr.

Systèmes perceptuels

L'œil humain ne perçoit pas la couleur comme une simple combinaison de composantes trichromatiques (rouge, vert, bleu), mais plutôt selon des entités liées à la luminosité, la teinte et la saturation [3]. Ainsi, les espaces de couleur perceptuels décrivent la couleur en utilisant trois composantes principales : luminosité, teinte et saturation [3, 39]. Dans la littérature, on trouve de nombreux systèmes de ce type telles que HSI, HSV, HSL, TLS, LCH, LSH, LST, ITS, etc [3, 40].

Espace HSV : l'espace de couleur HSV (Hue, Saturation, Value) sépare la composante de teinte des composantes de saturation et de valeur [41].

- *Teinte* : la teinte (en anglais Hue) est considérée comme la couleur de base, avec une valeur allant de 0 à 360 degrés, couvrant tout le spectre des couleurs.
- *Saturation* : la saturation décrit l'intensité ou la pureté de la couleur. Elle est généralement exprimée en pourcentage, allant de 0% à 100%.
- *Luminance* : la luminance (en anglais value) représente la luminosité ou la brillance de la couleur. Elle est généralement exprimée en pourcentage, allant de 0% (noir) à 100% (blanc).

L'espace de couleur HSV peut être visualisé sous la forme d'un cône (figure (2.13)) :




FIGURE 2.13 – Représentation de l'espace HSV.

Le passage de l'espace RVB à l'espace HSV est donné par les équations mathématiques suivantes [41] :

$$H = \arccos \frac{\frac{1}{2}((R - G) + (R - B))}{\sqrt{((R - G)^2 + (R - B)(G - B))}} \quad (2.29)$$

$$S = 1 - 3 \frac{\min(R, G, B)}{R + G + B} \quad (2.30)$$

$$V = \frac{1}{3}(R + G + B) \quad (2.31)$$

Espace HSL : cet espace de couleur est basé sur les trois composantes : H représente la teinte pure de la couleur, S (Saturation) mesure l'intensité ou la pureté de la couleur, et L (Luminance) représente la clarté de la couleur. La figure (2.14) illustre la représentation de cet espace colorimétrique.




FIGURE 2.14 – Représentation de l'espace HSL.

Le passage de l'espace RVB à l'espace HSL est donné par les formules suivantes [4,42] :

$$H = a \cos \left[\frac{((R - V) + (R - B))}{2\sqrt{(R - V)^2 + (R - B)(V - B)}} \right] \quad (2.32)$$

$$S = 1 - \frac{3 \min(R, V, B)}{L} \quad (2.33)$$

$$L = R + V + B \quad (2.34)$$

Systèmes d'axes indépendants

Les composantes des espaces de couleur que nous avons étudiés jusqu'à présent sont plus ou moins corrélées. L'objectif de ce type d'espace est de parvenir à une complète décorrélation entre les différentes composantes de couleur, c'est-à-dire que chaque composante serait totalement indépendante des autres. Trois approches sont disponibles pour résoudre ce problème de corrélation [3] : Analyse en composantes principales (ACP), analyse en composantes indépendantes (ACI), système d'Ohta : il existe une transformation unique appelée (I1, I2, I3). Les coordonnées de l'espace Ohta I1, I2 et I3 sont calculées en utilisant la conversion suivante [3,43] :

$$I1 = \frac{1}{3}(R + G + B) \quad (2.35)$$

$$I2 = (R - B) \quad (2.36)$$

$$I3 = \frac{1}{2}(2G - (R + B)) \quad (2.37)$$

Il existe d'autres espaces de couleur tel que CMYK et GGB ... etc. *Espace CMYK* :

(cyan, magenta, jaune, noir) est largement utilisé dans l'impression pour décrire les couleurs (figure (2.15)). Chaque lettre représente une composante de couleur primaire, avec le noir ajouté pour améliorer la profondeur des tons sombres [44]. Pour obtenir cette composante, on calcule le minimum des composantes C, Y et M :

$$K = \min(C, Y, M) \quad (2.38)$$




FIGURE 2.15 – Représentation de l'espace CMYK.

Espace GGB : c'est un espace de couleur crée pour une sélection appropriée des régions ainsi que pour le traitement des images médicales sanguines. Cet espace exprimé en trois composantes (G_n, B_n), tel que G_n est une composante normalisée de G (RGB) et améliorée en contraste et B_n la composante normalisée de B (RGB) [45].

Avec :

$$G_n = \frac{G}{MG} \quad (2.39)$$

$$B_n = \frac{B}{MB} \quad (2.40)$$

$$GGB = G_n G_n B_n \quad (2.41)$$

Avec :

MG : Moyenne de la composante verte (G).

MB : Moyenne de la composante bleu (B).

2.4.2 Texture

La texture est une caractéristique de l'image, qui joue un rôle important dans la segmentation d'image. Les approches les plus couramment utilisées pour caractériser la texture incluent les matrices de cooccurrence, les filtres de Gabor et les ondelettes [39]. Il existe deux types de texture [46] :

- *Les macro-textures* : (ou textures structurées) se distinguent par des motifs élémentaires sont des formes ou des structures de base se répétant pour former une texture globale. Ces motifs peuvent être facilement identifiés et isolés.
- *Les micro-textures* : Les micro-textures désignent de petits motifs qui donnent un aspect désordonné tout en maintenant une uniformité visuelle. Ces caractéristiques minuscules sont invisibles à l'œil et nécessitent un microscope pour être observées.

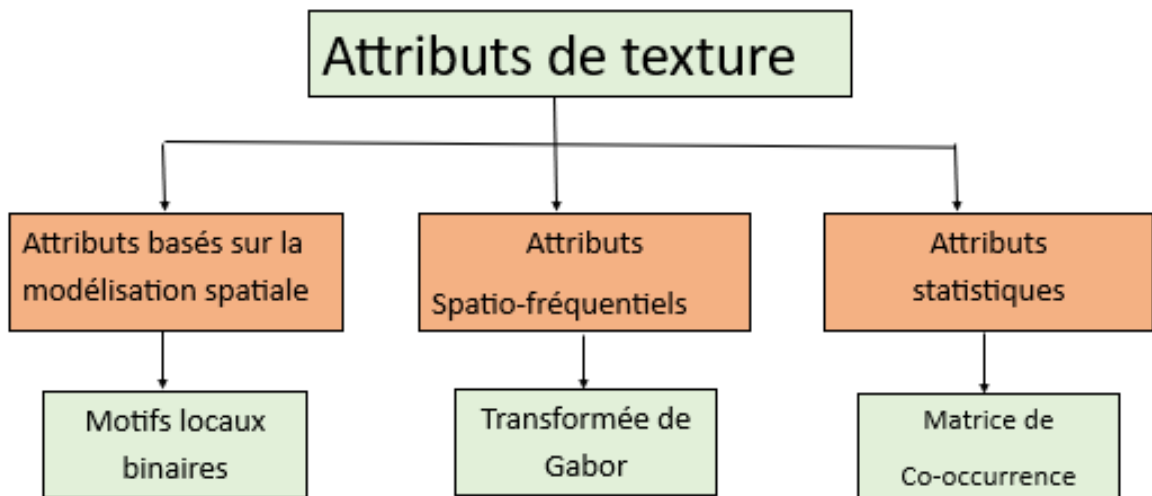


FIGURE 2.16 – Les différentes classes d'attributs de texture dans la littérature [6].

Les attributs de textures permettent de décrire la texture d'une image. Ils peuvent être classés en trois catégories [6] : attributs basés sur la modélisation spatiale, attributs spatio-fréquentiels, et attributs statistiques (figure (2.16)).

Attributs basés sur la modélisation spatiale : Ces attributs s'appuient sur la répartition des couleurs dans l'image. Parmi les méthodes les plus populaires, on trouve les motifs locaux binaires. *Les motifs locaux binaires* [6] : (LBP, Local Binary Patterns)

ou chaque pixel d'une image reçoit une valeur en fonction des niveaux des composantes de ses voisins. On compare les niveaux des composantes couleur du pixel central à celle de ses voisins immédiats. Si les niveaux des composantes couleur d'un voisin est supérieure ou égale à celle du pixel central, on lui attribue la valeur 1. Sinon, il reçoit la valeur 0. En multipliant cette matrice binaire par des poids spécifiques et en additionnant les résultats, on obtient la valeur LBP du pixel central. Cette méthode permet de capturer à la fois des informations spatiales et spectrales sur la texture de l'image [6]. LBP est défini par [46] :

$$LBP(xc, yc) = \sum_{p=0}^{P-1} S(g_p - g_c) \cdot 2^p \quad (2.42)$$

Où :

- g_c est le niveau de composante du pixel central de coordonnées (xc, yc) .
- $g_p (p = 0, 1, \dots, 7)$ est le niveau de composante de chaque pixel voisin.

Avec :

$S(x)$ une fonction définie comme suit :

$$\begin{aligned} S(x) &= 1 \quad \text{si } x \geq 0 \\ S(x) &= 0 \quad \text{si } x < 0 \end{aligned}$$

La figure (2.17) ci-dessous illustre un exemple de calcul d'un LBP.




FIGURE 2.17 – Illustration de calcul d'un LBP (8 voisins).

Attributs spatio-fréquentiels : Les attributs spatio-fréquentiels constituent une catégorie d'attributs qui caractérise la texture en tenant compte à la fois de sa structure spatiale et de sa distribution fréquentielle (la fréquence des variations d'intensité des pixels dans l'image) [6]. Parmi ces méthodes, on trouve la transformée de Gabor.

La transformée de Gabor : Le filtre de Gabor est un filtre linéaire et local, largement utilisé pour la description des textures. Il s'applique à une image à l'aide d'un ensemble de filtres, chacun étant défini par sa fréquence et son orientation. Il est représenté par une fonction sinusoidale modulée par une enveloppe gaussienne. Son ondelette de base est définie de la manière suivante [47].

$$g(x, y) = \frac{1}{2\pi\sigma_x\sigma_y} \exp \left[- \left(\frac{x_\theta^2}{\sigma_x} + \frac{y_\theta^2}{\sigma_y} \right) \right] \cos(2\pi f_c x + \phi) \quad (2.43)$$

où :

σ_x est l'écart-type de la fonction gaussienne dans direction horizontale le long du filtre, qui détermine la largeur de bande du filtre.

σ_y est l'écart-type de la fonction gaussienne à travers le filtre qui contrôle la sélectivité d'orientation du filtre.

f_c est la fréquence centrale de la bande passante.

ϕ est l'orientation du filtre.

x_θ et y_θ sont les coordonnées après rotation d'un angle θ .

Dans le domaine spatial, l'application des filtres de Gabor se réalise en effectuant la convolution de chaque filtre avec l'image, ce qui permet d'obtenir une réponse. Ce procédé est décrit par l'équation suivante :

$$I_{Gabor}(x, y) = g(x, y) * I(x, y) \quad (2.44)$$

où :

$I_{Gabor}(x, y)$ est le pixel filtré de l'image résultat.

$I(x, y)$ est le pixel de l'image originale.

Les réponses obtenues pour chaque pixel de l'image représentent des caractéristiques locales de texture. Pour chaque filtre, des statistiques sont calculées à partir de l'image filtrée afin d'en extraire des attributs. Les attributs les plus couramment utilisés sont les suivants : L'énergie, l'écart-type et la moyenne.

Attributs statistiques : Les attributs statistiques sont basés sur l'analyse de la distribution des valeurs de pixels dans l'image. Parmi ces méthodes on peut citer les matrices de co-occurrences.

Matrice de cooccurrence au niveau de gris GLCM : Les GLCM ont été introduites par Haralick pour les images en niveaux de gris. Par la suite, elles ont été étendues aux images couleur. L'intérêt de ces matrices est qu'elles fournissent des informations sur la façon dont les couleurs sont distribuées dans l'image. Pour calculer cette matrice, il est nécessaire de choisir une distance v de déplacement et un angle θ [48]. La figure (2.18) ci-dessous illustre ces paramètres, et la figure (2.19) montre un exemple sur cette matrice.




FIGURE 2.18 – Illustration des paramètres de GLCM.

0	0	1	2
0	1	3	2
0	2	3	2
1	2	3	0

$$p_{d,\theta(1,0^\circ)} = \begin{bmatrix} 2 & 2 & 1 & 1 \\ 2 & 0 & 2 & 1 \\ 1 & 2 & 0 & 4 \\ 1 & 1 & 4 & 0 \end{bmatrix} \quad p_{d,\theta(1,45^\circ)} = \begin{bmatrix} 2 & 1 & 0 & 0 \\ 1 & 2 & 1 & 0 \\ 0 & 1 & 0 & 5 \\ 0 & 0 & 5 & 0 \end{bmatrix}$$

$$p_{d,\theta(1,90^\circ)} = \begin{bmatrix} 4 & 2 & 1 & 0 \\ 2 & 0 & 1 & 1 \\ 0 & 1 & 6 & 0 \\ 0 & 1 & 0 & 4 \end{bmatrix} \quad p_{d,\theta(1,135^\circ)} = \begin{bmatrix} 0 & 1 & 1 & 2 \\ 1 & 0 & 1 & 1 \\ 2 & 1 & 0 & 2 \\ 2 & 1 & 2 & 0 \end{bmatrix}$$

FIGURE 2.19 – Exemple de matrices de cooccurrence d'une image 4 * 4 composée de 4 niveaux de gris [7].

La construction de la matrice de cooccurrence $p_{d,\theta}(i, j)$ de la région R d'une image I est construite pour tout couple de niveaux de gris (i, j) de la façon suivante [49] :

$$p_{d,\theta}(i, j) = \text{card}\{(s, s + t) \in R^2 \mid I(s) = i, I(s + t) = j\} \quad (2.45)$$

où :

- $p_{d,\theta}(i, j)$ représente la relations spatiales entre les niveaux de gris des pixels d'une matrice de co-occurrence.
- i et j représentent les niveaux de gris des pixels.
- d représente la distance entre les deux points.
- θ représente la direction dans laquelle les points sont situés l'un par rapport à l'autre [50].

On normalise les matrices pour qu'elles aient toutes la même somme. Cela permet de les comparer plus facilement. Nous avons adopté cette approche, ce qui nous conduit à obtenir quatre matrices de cooccurrences pour chaque image. Ensuite, ces matrices sont normalisées selon la formule suivante [50] :

$$p_{d,\theta}(i, j) = \frac{p_{d,\theta}(i, j)}{\sum_i \sum_j p_{d,\theta}(i, j)} \quad (2.46)$$

A partir des matrices de co-occurrence, plusieurs attributs peuvent être calculés. Haralick à extrait quatorze attributs. Parmi eux :

Énergie : mesure la variation des niveaux de gris dans l'image. Les textures homogènes se caractérisent par des valeurs d'énergie élevées. Mathématiquement, elle est définie par la somme des carrés des éléments de la matrice de cooccurrence $p_{d,\theta}$.

$$Energie = \sum_i \sum_j (p_{d,\theta}(i, j))^2 \quad (2.47)$$

Contraste : le contraste mesure la variation entre les niveaux de gris des pixels voisins dans une image. Si le contraste est faible, cela signifie que les niveaux de gris sont similaires entre les pixels voisins. En revanche, un contraste élevé montre qu'il y a de grandes différences entre ces niveaux de gris.

$$Contraste = \sum_i \sum_j ((i - j)^2 p_{d,\theta}(i, j)) \quad (2.48)$$

Corrélation : la corrélation mesure la relation linéaire entre les niveaux de gris des pixels voisins. Elle indique comment les niveaux de gris d'un pixel sont liés à ceux de son voisin en fonction d'une direction et d'un déplacement donnés. Elle est définie mathématiquement comme [51].

$$Corrélation = \frac{\sum_{i,j} (i - \mu_i)(j - \mu_j)P(i, j)}{\sigma_i \sigma_j} \quad (2.49)$$

où :

μ_i et μ_j sont les moyennes des indices i et j .

σ_i et σ_j sont les écarts-types des indices i et j .

Homogénéité : l'homogénéité mesure à quel point les niveaux de gris sont uniformément repartis dans l'image. Si l'homogénéité est élevée, cela signifie que les différentes parties de l'image ont des niveaux de gris assez similaires, ce qui donne une texture plus lisse et régulière. Elle est définie par l'équation ci-dessous :

$$\text{Homogénéité} = \sum_i \sum_j \frac{p_{d,\theta}(i,j)}{1 + (i-j)^2} \quad (2.50)$$

2.5 Segmentation interactive d'images

La segmentation interactive d'images consiste à guider une segmentation vers la segmentation désirée en intégrant quelques informations a priori sur le domaine [52]. Cette méthode permet d'obtenir des résultats précis et adaptables, ajustés selon les besoins de l'utilisateur. Les informations fournies lors de l'interaction humaine permettent de corriger et d'affiner la segmentation automatique, assurant ainsi une qualité optimale. Cette approche trouve des applications variées dans la médecine, la surveillance, l'industrie et d'autres domaines où la précision et l'adaptabilité sont essentielles pour les traitements d'images avancés et les systèmes automatisés [53].

Le processus de segmentation interactive peut être représenté par le schéma illustré dans la figure (2.20).

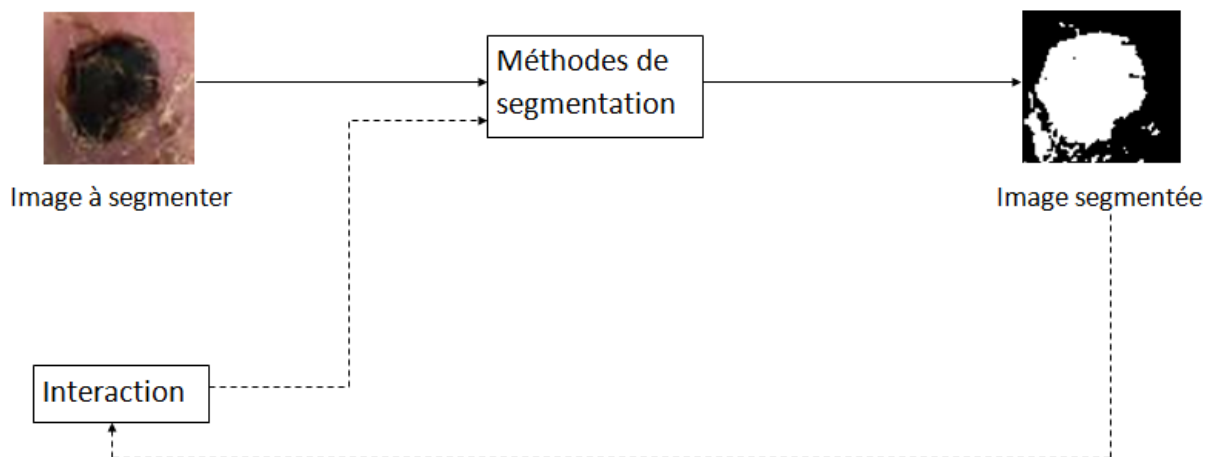


FIGURE 2.20 – Processus illustratif d'une méthode de segmentation interactive.

L'interaction peut être connue ou donnée par un utilisateur, un professionnel, ou un expert. Elle peut prendre différentes formes (des traits, des points, des box, des masques ... etc). La figure (2.21) ci-dessous illustre les différents types d'interaction.

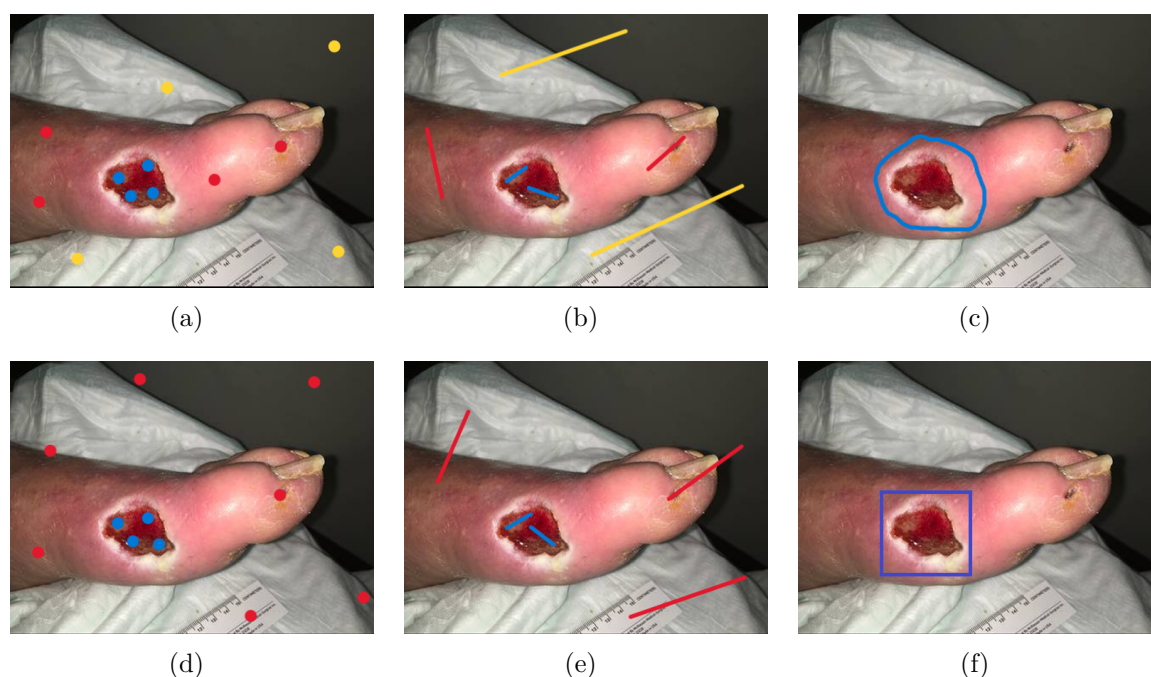


FIGURE 2.21 – Différents types d'informations à priori utilisés dans la segmentation interactive : (a) points (trois régions), (b) traits (trois régions), (c) dessiné, (d) points (deux régions), (e) traits (deux régions), (f) box.

La segmentation interactive représente un progrès majeur dans le domaine du traitement d'images et de l'analyse de données. Elle permet aux utilisateurs de travailler de manière étroite avec des algorithmes pour définir, ajuster et vérifier des segments avec précision. Par exemple, en médecine, les praticiens utilisent des outils interactifs pour segmenter des structures anatomiques complexes à partir d'images scanographiques, améliorant ainsi la précision des diagnostics. Dans le domaine du marketing numérique, les experts ajustent en temps réel les segments de clients en se basant sur des données comportementales et démographiques, améliorant ainsi l'efficacité des campagnes publicitaires ciblées. Cette approche interactive est également utilisée dans la personnalisation des services, la recherche scientifique et la gestion de données complexes, permettant aux utilisateurs d'améliorer leur analyse et leur interprétation des informations [54].

2.6 Conclusion

En conclusion, la segmentation interactive des images, représente une avancée significative pour l'analyse des données visuelles complexes. Malgré les défis liés à la subjectivité des utilisateurs et à la complexité des algorithmes, les méthodes de segmentation telles que le contour, la région et la classification offrent une flexibilité essentielle pour identifier avec précision les régions et structures dans les images. L'utilisation des attributs de couleur et de texture est cruciale pour évaluer les lésions de manière efficace. L'évolution continue de la segmentation d'images promet d'améliorer constamment la précision et la compréhension visuelle, renforçant ainsi son rôle central dans des applications diverses allant de la médecine à l'industrie.

3

CLASSIFICATION DES PIXELS

3.1 Introduction

Dans ce chapitre, nous explorons la classification, une étape essentielle pour identifier les structures sous-jacentes des pixels. Tout d'abord, nous définirons clairement ses concepts, en explorant les différentes approches de classification. Ensuite, nous plongerons dans la classification supervisée, où des algorithmes tels que K-NN (K plus proches voisins) et SVM (Machines à vecteurs de support) sont utilisés pour classer des pixels étiquetés. Par la suite, nous nous introduisons la classification non supervisée, où des algorithmes tels que k-means, k-Medoids, FCM, la classification hiérarchique, la classification spectrale et DBSCAN sont décrits. Enfin, nous explorons la classification semi-supervisée, dans le but d'améliorer les performances de nos méthodes non supervisées et supervisées. Au cours de cette exploration, nous décrirons des méthodes semi-supervisées telle que k-means semi-supervisé, COP-K-means semi-supervisé, et la classification hiérarchique semi-supervisée.

3.2 Classification

La classification des pixels consiste à regrouper des pixels en k classes selon un critère d'homogénéité, par exemple : la distance, la similarité, la dissimilarité ... etc. Les pixels dans une même classe sont similaires par contre les pixels entre deux classes différentes sont dissimilaires.

Selon la présence ou non d'une quantité d'information a priori sur les classes, la classification peut être soit supervisée, non supervisée ou semi-supervisée.

3.2.1 Classification supervisée

La classification supervisée consiste à entraîner un algorithme pour prédire la classe à laquelle chaque ensemble de pixels appartient. Dans ce processus, l'algorithme est formé sur un ensemble de pixels étiquetés où chaque pixel est déjà associé par l'expert à une classe connue. En utilisant ces pixels connus, l'algorithme apprend à classifier correctement de nouveaux ensembles de pixels qui ne contiennent pas d'informations appropriées sur les classes. Parmi les méthodes les plus populaires, on trouve : l'algorithme des plus proches voisins (k-Nearest Neighbors, k-NN) [55, 56], SVM (machine à vecteurs de support) [57, 58], ... etc.

3.2.2 Classification non supervisée

En classification non supervisée, les méthodes existantes identifient les classes dans un ensemble de données (ensemble de pixels dans une image) sans utiliser aucune information a priori sur les classes. Généralement ces méthodes explorent la structure sous-jacente des données et révèlent des relations entre elles. Parmi les méthodes les plus populaires, on trouve : k-means [59], fuzzy c-means (FCM) [33], K-medoids [35], classifications hiérarchique [60], DBSCAN [34], ... etc.

3.2.3 Classification semi-supervisée

La classification semi-supervisée se situe entre la classification supervisée et classification non supervisée. Elle utilise à la fois un ensemble de pixels comportant des classes connues, où les informations sur les classes sont disponibles, et un autre ensemble de pixels où certaines classes sont inconnues a priori. En général, la taille des pixels avec des classes inconnues est bien plus grande que celle des pixels avec des classes connues. Parmi les méthodes les plus populaires, on trouve : k-means semi-supervisé [61], fuzzy c-means semi-supervisé (FCM), classifications hiérarchique semi-supervisée [62], COP-K-means [63] ... etc.

L'approche semi-supervisée fonctionne mieux lorsque les conditions suivantes sont remplies :

- Si deux pixels se trouvent dans des régions où il y a beaucoup de pixels proches, ils devraient appartenir à la même classe.
- Si deux pixels sont dans la même classe de données non supervisées, il est probable qu'ils soient dans la même classe.
- La frontière de séparation entre les classes se situe généralement dans des régions où il y a moins de pixels.

La figure (3.1), schématise les différentes approches de classification.

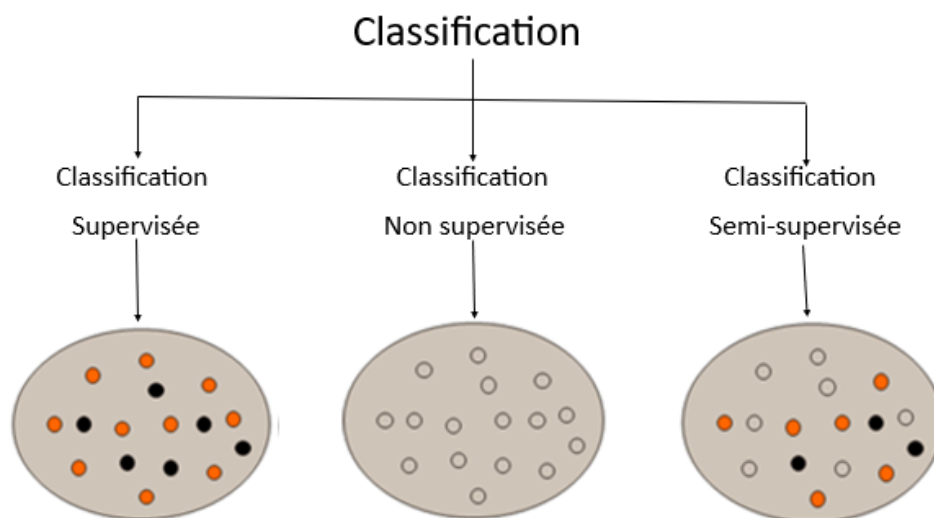


FIGURE 3.1 – Différentes approches de classification [les pixels en couleur orange et noir sont connus, et les pixels sans couleur sont inconnus].

3.3 Exemples de méthodes supervisées

Dans cette section, nous décrivons les algorithmes de classification supervisée K-NN et SVM.

3.3.1 k-Nearest Neighbors (k-NN)

L'algorithme des k-plus proches voisins, est un algorithme des Machines Learning appartenant à la catégorie des méthodes de classification supervisée simple, et facilement à implémenter. K-NN utilise des données existantes pour classifier de nouveaux pixels en se basant sur des mesures de similarité, généralement exprimées par des fonctions de distance [56, 58]. Le classement se fait à la majorité de ses voisins. Ainsi, les pixels sont affectés à la classe qui a les voisins les plus proches [58]. Il est non paramétrique et repose sur le principe du voisinage.

Algorithme 3.1: L'algorithme des K-NN [49]

Entrée :

Ensemble de pixels, noté par N . Ensemble de pixels déjà classés pour chaque classe noté par $\Omega = (\Omega_{k_1}, \Omega_{k_2}, \Omega_{k_c})$.

Sortie :

Une partition de k classes (K_1, K_2, \dots, k_c) .

Début

1. Pour chaque pixel n_i à classer :
 - mesurer la distance du pixel n_i avec tous les pixels déjà classés Ω .
 - déterminer la liste des K pixels déjà classés les plus proches de n_i .
 - déterminer la classe la plus représentée dans la liste des K-NN et affecter notre pixel n_i à cette classe.

Fin

3.3.2 Support Vector Machines (SVM)

Les Support Vector Machines (SVM), est une méthode de classification supervisée. Son principe est de séparer un ensemble de données en deux classes à l'aide d'un hyperplan optimal. Les paramètres de cet hyperplan sont choisis de manière à maximiser la distance minimale par rapport aux pixels déjà classés, cette distance est appelée marge. Les points les plus proches de l'hyperplan, utilisés pour déterminer ce dernier, sont appelés vecteurs de support. Une fois le modèle entraîné, il peut décider de l'appartenance d'un nouveau pixel à une classe ou à une autre [64]. Un exemple est représenté par la figure (3.2).




FIGURE 3.2 – Principe des SVM.

3.4 Exemples de méthodes non supervisées

Dans cette section, nous décrivons les algorithmes de classification non supervisée Kmeans, FCM et Kmedoid :

3.4.1 K-means

L'algorithme K-means est créé par MacQueen en 1976 [65,66], est l'un des algorithmes de classification non supervisés les plus simples et efficaces. La méthode de segmentation par K-means consiste à fixer un nombre V_c centroides aléatoire pour associer chaque pixel au point central le plus proche jusqu'à ce qu'un critère d'arrêt soit atteint. À chaque regroupement, nous calculons un nouveau centre en prenant la moyenne des pixels d'une classe. Ce processus est répété jusqu'à ce qu'aucun pixel ne change de classe, ce qui signifie que les classes sont stables. Cependant, les résultats peuvent varier en fonction de la partition initiale. Étant donné que la partition initiale est aléatoire, l'algorithme K-means est non déterministe.

Avantages

1. Simple et compréhensible.
2. Rapidité et efficacité dans la création des classes.

Algorithme 3.2: K-means [59]

Entrée :

Ensemble de pixels, noté par N .

Nombre de classes souhaité, noté par k .

Sortie :

Une partition de k classes (k_1, k_2, \dots, k_c) .

Début

1. Initialiser les V_c centres de classes de manière aléatoire.
2. Affecter chaque pixel au centre de classe la plus proche.

$$n_i \in k_c \text{ si } \forall j, \|n_i - v_c\| = \min_j \|n_i - v_j\| \quad (3.1)$$

Où :

- n_i représente un pixel de l'ensemble.
 - k_c est la c -ème classe.
 - v_c est le centre de la c -ème classe.
 - $\|n_i - v_c\|$ représente la distance entre n_i et v_c .
3. Recalculer les centres de classes en utilisant la moyenne des pixels affectés à chaque centre.

$$v_c = \frac{1}{N} \sum_{n_i \in k_c} n_i \quad (3.2)$$

4. Répéter les deux dernières étapes jusqu'à ce que les centres de classes ne bougent plus ou que le nombre d'itérations maximum soit atteint.

Fin

3.4.2 Fuzzy c-means

Fuzzy C-means est un algorithme de classification non supervisée qui utilise la logique floue pour classer les pixels similaires dans des classes en se basant sur la moyenne de chaque classe. Son utilité réside dans sa capacité à générer des résultats efficaces pour la segmentation d'images bruitées. FCM vise à minimiser une fonction objective qui mesure la dispersion des pixels à l'intérieur de chaque classe, appelée variance intra-classe. Cette fonction est définie ainsi [33] :

$$J(U, \mathbf{V}) = \sum_{i=1}^N \sum_{c=1}^k u_{ic}^m \|n_i - v_c\|^2 \quad (3.3)$$

où :

- U représente la matrice de partition.
- u_{ic} est le degré d'appartenance du point de données x_i au c -ème classe.
- m est le paramètre de flou, qui contrôle le degré de chevauchement entre les classes.
- v_c est le centre de la c -ème classe.
- $\|n_i - v_c\|^2$ est la distance euclidienne entre le pixel x_i et le centre d'une c -ème classe.

Algorithme 3.3: FCM

Entrée :

Ensemble de pixels, noté par N .

Nombre de classes souhaité, noté par k .

Sortie :

Une partition de K classes (k_1, k_2, \dots, k_c) .

Début

1. *Mise à jour des centres des classes.*

$$\mathbf{v}_c = \frac{\sum_{i=1}^N u_{ic}^m n_i}{\sum_{i=1}^N u_{ic}^m} \quad (3.4)$$

2. *Mise à jour des degrés d'appartenance*

$$u_{ic} = \left[\frac{d(n_i, v_c)}{d(n_i, v_j)} \right]^{-\frac{2}{m-1}} \quad \forall j = 1, \dots, K \quad (3.5)$$

Fin

3.4.3 Classification hiérarchique

La classification hiérarchique est une méthode de classification non supervisée qui vise à organiser un ensemble de pixels en classes homogènes, en suivant une structure arborescente appelée dendrogramme. Un dendrogramme est un arbre qui représente la hiérarchie des classes et la hauteur de chaque branche du dendrogramme représente la distance entre les classes correspondants. Le dendrogramme permet de visualiser la structure des classes et de choisir le nombre le plus approprié.

3.4.4 k-Médoïdes

L'algorithme de classification K-Médoïdes, également connu sous le nom de Partitionnement Autour de Médoïdes, est une méthode robuste de classification non supervisée de pixels. Contrairement à l'algorithme Kmeans, qui se base sur la moyenne des pixels, K-Médoïdes choisit des médoïdes parmi les pixels eux-mêmes, offrant ainsi une approche plus flexible et résistante. Cette méthode est particulièrement adaptée aux pixels présentant des valeurs aberrantes ou des mesures de distance arbitraires. En utilisant des médoïdes comme centres de classes, K-Médoïdes est efficace même dans les cas où la moyenne n'est pas définie, ce qui en fait une option précieuse pour classer divers types de pixels.

K-Médoïdes vise à minimiser les distances entre les pixels et les centres de leurs classes [35].

Algorithme 3.4: Algorithme k-Medoids

Entrée :

Ensemble de pixels, noté par N .

Nombre de classes souhaité, noté par k .

Sortie :

Une partition de k classes (k_1, k_2, \dots, k_c) .

Début

1. Choisir un ensemble de médoïde.
2. Attribuer chaque individu au médoïde le plus proche.
3. Affiner les centres de classe pour minimiser la distance interne répéter jusqu'à ce que les médoïdes ne changent pas ou que d'autres critères de terminaison soient remplis.

Fin

Il existe deux approches principales pour la classification hiérarchique qui sont [60] : la classification ascendante hiérarchique et la classification descendantes hiérarchique.

3.4.5 DBSCAN

DBSCAN est un algorithme de classification non supervisé conçu pour classer des pixels en classes en fonction de leurs proximité. Il ajuste automatiquement sa structure aux données sans besoin d'intervention humaine pour déterminer le nombre optimal de classes. Ses paramètres clés sont minPts , définissant le nombre minimum de points requis pour former une classe dense, et epsilon , une mesure de distance pour déterminer la proximité entre les points [34]. DBSCAN classe les pixels en trois catégories (classes) : centraux, frontières et valeurs aberrantes, en fonction de leur relation avec les autres pixels dans leur voisinage. Sa flexibilité et sa robustesse face au bruit et aux valeurs aberrantes en font un outil efficace pour l'analyse de données complexes, en que le choix des paramètres puisse être délicat [34].




FIGURE 3.3 – Principe des DBSCAN [8].

3.5 Exemples de méthodes semi-supervisées

Il y a plusieurs algorithmes semi-supervisés, parmi lesquels, on peut mentionner :

3.5.1 K-means semi-supervisé

K-means semi-supervisé est une version améliorée de l'algorithme de classification K-Means non supervisé, qui utilise une petite quantité de données étiquetées pour optimiser la qualité de classification. Contrairement au K-means non supervisé, où toutes les données sont non étiquetées et où l'algorithme doit déterminer les centres des classes de manière autonome, le K-means semi-supervisé commence avec un petit ensemble de données étiquetées fourni par l'utilisateur pour initialiser les centres des classes. Cette méthode est efficace, car elle peut améliorer la qualité de classification et réduire la sensibilité au choix du nombre de classes. Toutefois, la performance du K-means semi-supervisé est fortement tributaire de la qualité des données étiquetées et peut poser des difficultés si ces dernières sont bruitées ou incorrectement étiquetées.

On a un ensemble de données N à diviser en k classes disjointes $\{N_h\}_{h=1}^k$. Le but est de minimiser un objectif. soit $S \subset N$ un sous ensemble de données, appelé ensemble de départ. Chaque donnée $n_i \in \Omega$ a une étiquette $y_i = h$ qui indique la classe k_c auquel il appartient. Cet ensemble Ω est divisé en L sous-ensembles disjoints $\{\Omega_{k_c}\}_{h=1}^L$ où $L \leq k$ [67].

Algorithme 3.5: K-means semi-supervisé

Entrée :

Ensemble de pixels déjà classés Ω .

Nombre de classes souhaité, noté par k .

Ensemble de pixels de l'image, noté par N .

Sortie :

Une partition de k classes (k_1, k_2, \dots, k_c) .

Début

1. Initialiser les centres de classes en utilisant les pixels déjà classés.

$$v_c = \frac{1}{|\Omega_{k_c}|} \sum_{n_i \in \Omega_{k_c}} n_i, \text{ avec } k_c = 1, \dots, k \quad (3.6)$$

2. Affecter chaque pixel au centre de classe la plus proche.

$$n_i \in k_c \text{ si } \forall j, |n_i - v_c| = \min_j |n_i - v_j| \quad (3.7)$$

3. Recalculer les centres de classes en utilisant la moyenne des pixels affectés à chaque centre.

$$v_c = \frac{1}{N} \sum_{n_i \in k_c} n_i \quad (3.8)$$

4. Répéter les deux dernières étapes jusqu'à ce que les centres de classes ne bougent plus ou que le nombre d'itérations maximum soit atteint.

Fin

3.5.2 COP-k-means

L'algorithme de COP-k-means représente une adaptation de l'algorithme de K-means non supervisé, avec l'ajout de contraintes de liaison. Ces contraintes sont basées sur des pixels préalablement identifiés et sont utilisées pour restreindre le processus de classification du k-means. Ces contraintes sont un moyen utile pour exprimer une information a priori sur les pixels [63]. Il existe deux catégories de contraintes :

- *Contraintes Must-link* : désigne que deux pixels doivent être dans une même classe.
- *Contraintes (Cannot-link)* : désigne que deux pixels ne doivent pas être dans une même classe.

Algorithme 3.6: Algorithme COP-K-means [68]

Entrée :

Ensemble de données N ,
nombre de classes k ,
contraintes du lien obligatoire $Con =$,
contraintes de non liaison $Con \neq$.

Sortie :

Nombre de classes k_1, \dots, k_c .

Début

1. Initialiser les centres de classes V_1, \dots, V_k .
2. Chaque pixel $n_i \in N$ est assigné à sa classe la plus proche tout en assurant qu'aucune contrainte $Con =$ et $Con \neq$ n'est brisée.
3. Mis à jour de chaque centre de classe pour être la moyenne de tous les régions.
4. Répéter (2) et (3) jusqu'à la convergence.

Fin

3.6 Conclusion

Dans ce chapitre, nous avons exploré plusieurs méthodes de segmentation par classification supervisée, non supervisée et semi-supervisée. Les méthodes par classification supervisée, telles que K-NN et SVM, nécessitent des données étiquetées pour former le modèle. En revanche, les méthodes par classification non supervisée comme K-means, permettent de découvrir la classification des données sans aucune information à priori. Parallèlement, les méthodes de segmentation par classification semi-supervisée comme COP-K-means, combine des données non connues avec des contraintes d'étiquetages pour améliorer la précision de la segmentation. Le choix de la meilleure approche dépendra des données disponibles et des régions spécifiques de la segmentation.

4

APPROCHE PROPOSÉE

4.1 Introduction

La segmentation d'images est une étape cruciale dans le processus d'analyse d'images médicales, notamment dans le domaine de la dermatologie pour la détection et la caractérisation des ulcères. Dans ce chapitre, nous présentons notre approche de segmentation interactive par classification des pixels. Nous commencerons par étudier les attributs extraits ainsi que plusieurs méthodes de classification tels que : K-means, FCM, et K-Medoids. Par la suite, nous intégrerons l'interaction de l'utilisateur dans une segmentation par classification semi-supervisée, avec K-means semi-supervisé.

Notre système propose une approche en plusieurs étapes qui combine l'interaction humaine avec des techniques de traitement d'images. Ces étapes commencent par une phase d'acquisition d'images, suivie d'une phase d'annotation (interaction de l'utilisateur), puis d'une phase de classification, d'extraction des attributs, de segmentation, jusqu'à l'obtention d'une image segmentée et améliorée par un post-traitement.

Dans notre étude, nous avons choisi d'appliquer une segmentation interactive car toute interaction ajoutée par l'utilisateur nous mènera à une meilleure segmentation.

4.2 Approche proposée

Notre approche est constituée de plusieurs étapes qui se suivent (voir la figure (4.1)).

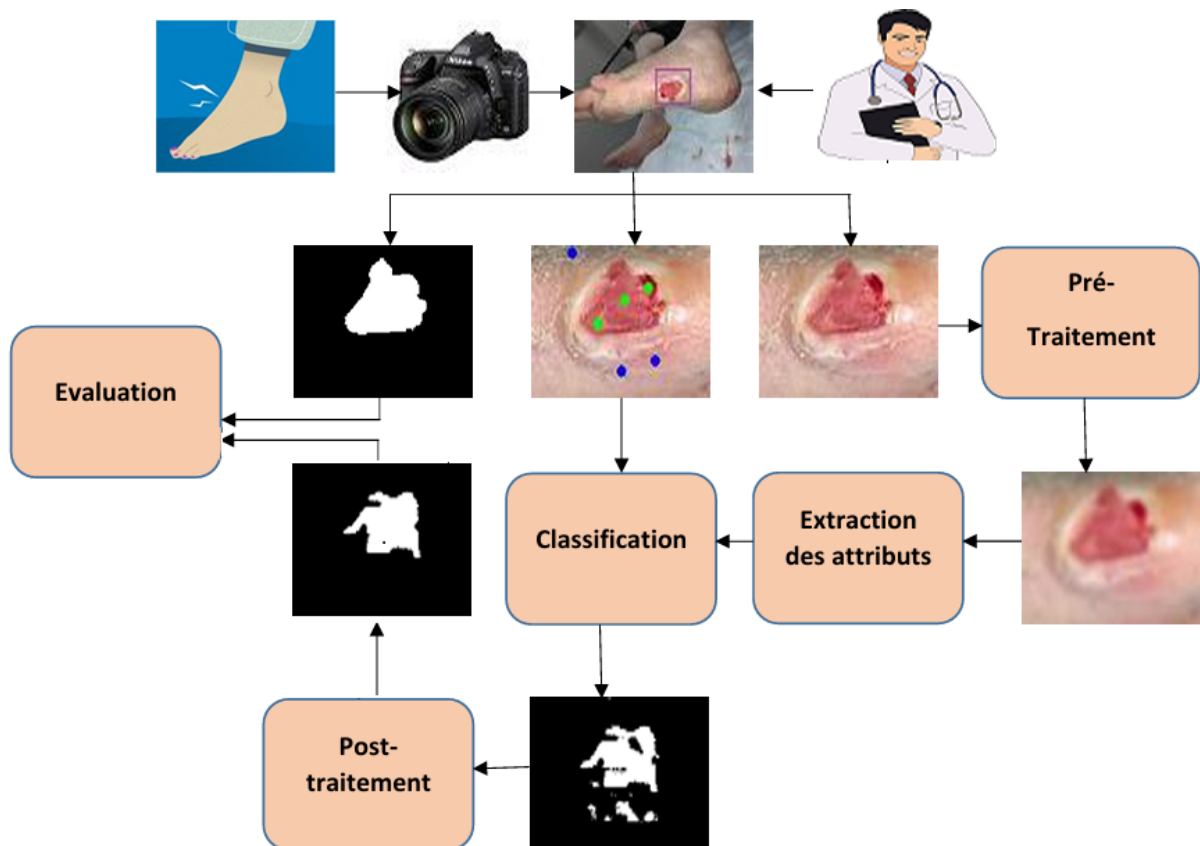


FIGURE 4.1 – Schéma illustratif des étapes du travail.

- *Acquisition et interaction de l'utilisateur* : Pour l'analyse que nous allons effectuer dans notre travail, nous avons choisi un ensemble d'images de manière aléatoire à partir de la base d'images " Wound and Vascular Center".

Cette base d'images a été collecté sur une période de deux ans, d'octobre 2019 à avril 2021, et comprend 1 210 images d'ulcères du pied, prises auprès de 889 patients lors de multiples visites cliniques. Les images brutes ont été capturées à l'aide d'un appareil photo numérique Canon SX 620 HS et d'un iPad Pro, dans des conditions d'éclairage incontrôlées et avec différents arrière-plans.

Nous avons sélectionné douze images pour l'ajustement des paramètres et l'étude des différentes étapes qui constitue notre approche de segmentation d'images (figure (4.2)), sachant que la base de données contient les vérités terrain. Ensuite, nous avons utilisé huit autres nouvelles images, non impliquées dans l'étude, pour tester l'efficacité de l'approche de segmentation proposée (figure (4.3)).



FIGURE 4.2 – Les images utilisées pour l'étude des paramètres.

L'utilisateur délimite ensuite la région qui contient la zone d'intérêt en dessinant un box sur l'image puis sélectionne sur l'imagette des annotations précisant si les pixels sont annoter par des marques vertes indiquant qu'ils appartiennent à la région d'intérêt (peau infecter) ou par des marques bleues indiquant qu'ils appartiennent aux autres régions (figure(4.4)).



FIGURE 4.3 – Images de test.

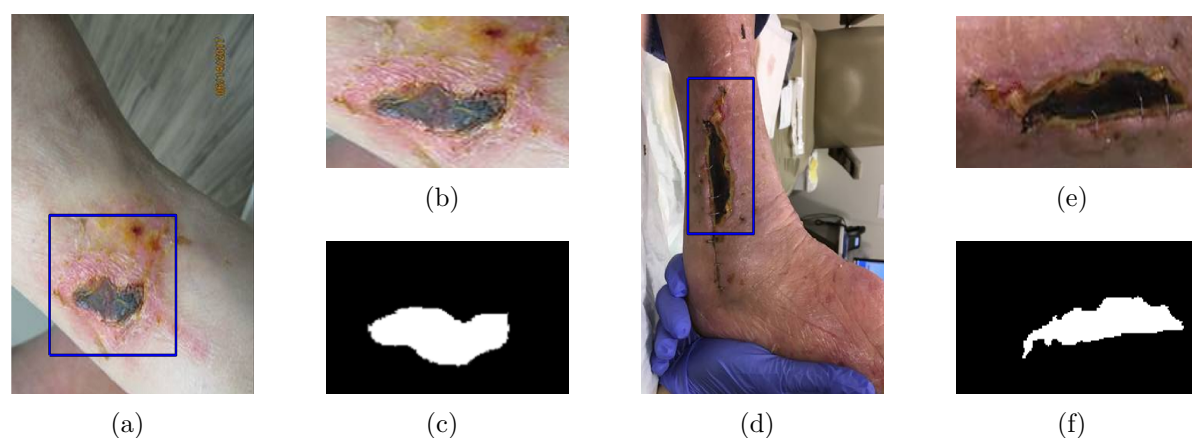


FIGURE 4.4 – Détermination de la région d'intérêt par interaction de l'utilisateur : (a) et (d) images originales, (b) et (e) imageries, (c) et (f) vérités terrains.

- **Pré-traitement** : Il existe plusieurs pré-traitement pour améliorer la qualité des images. Ici, nous avons utilisé le filtre gaussien pour éliminer le bruit.
- **Extraction d'attributs** : Dans notre travail, nous exploitons deux types d'attributs : les attributs de couleur (Gray, Lab, RGB, YCbCr, YIQ, HSV, Cmyk, UVL, HSL, XYZ, et GGB) et les attributs de texture (Gabor et Haralick).
- **Classification** : Nous avons choisi trois méthodes de segmentation par classification (K-means, Fuzzy C-means, K-Medoids). Par la suite, nous devons sélectionner la méthode la plus performante pour implémenter sa version semi-supervisée pour améliorer d'avantages les performances.
- **Post-traitement** : Cette étape comporte plusieurs traitements permettant d'amé-

liorer la segmentation des images. Dans notre étude, nous utiliserons des opérations de morphologie mathématique : ouverture fermeture, et remplissage des trous et élimination des petites régions.

- **Évaluation** : Pour évaluer les résultats de segmentation nous avons choisi d'utiliser l'accuracy (taux de bonne classification des pixels de l'imagette) par le biais du calcul de la matrice de confusion. Elle est une matrice carrée qui rapporte le nombre de true positifs (TP), true négatifs (TN), false positifs (FP) et false négatifs (FN), à partir de ces quatre valeurs on peut calculer le taux de bonne classification (Accuracy). Elle est définie par :

$$\text{Accuracy} = \frac{(TP + TN)}{(FN + FP + TP + TN)} \quad (4.1)$$

4.3 Étude des attributs extraits

Au cours de cette étape, une variété d'attributs de couleur et de texture ont été étudiés.

4.3.1 Attributs de couleur

Pour étudier les attributs de couleur, nous avons comparé les performances de chacune des combinaisons possibles des espaces de couleur ($2^{11} - 1$). Puis, nous avons sélectionné la combinaison qui offre le meilleur taux de bonne classification. Pour chacune des images utilisées nous avons appliqué trois méthodes de classification à savoir kmeans (KMS), FCM, et Kmedoid (KMD). Le tableau (4.1) présente les meilleurs résultats d'Accuracy obtenus par les meilleurs espaces de couleur sélectionnés pour chaque image par les trois méthodes de segmentation par classification (K-means, FCM, K-medoids). On observe que les espaces de couleur Lab et GGB se distinguent comme les plus performants, même lorsqu'ils sont utilisés de manière individuelle sans être combinés avec d'autres espaces de couleur.

Pour déterminer les espaces de couleur que nous utiliserons prochainement, nous avons calculé le nombre de fois où chaque espace colorimétrique a été identifié comme appartenant aux meilleures combinaisons d'espaces de couleur.

Le tableau (4.2) indique le nombre d'occurrences de chaque espace colorimétrique utilisé par chaque méthode de segmentation par classification (K-means, FCM, K-medoids), ainsi que la somme totale d'utilisation.

Nos résultats ont révélé que l'espace Lab est le plus utilisé. Ensuite, l'espace GGB se positionne comme le deuxième choix préféré. Les espaces HSL, HSV et Gray suivent respectivement.

Pour déterminer la méthode de segmentation par classification la plus efficace, nous avons calculé une moyenne pour les résultats de chaque méthode comme indiqué dans le tableau (4.3). Nous concluons que :

Les meilleurs performances sont obtenues par K-means et K-Medoids avec une très petite différence.

Image	Méthodes	Accuracy	Espaces de couleur sélectionnés
Im0021	KMS	86,36	Lab-YCbCr-GGB
	FCM	86,13	GGB
	KMD	86,76	GGB
Im0051	KMS	83,80	Gray-Lab-HSV-HSL
	FCM	67,67	Lab
	KMD	83,80	Gray-Lab-HSV-XYZ-HSL
Im0099	KMS	98,69	YCbCr-YIQ-HSV-UVL-HSL
	FCM	98,64	Lab-HSV-UVL-HSL
	KMD	98,53	UVL-GGB
Im0191	KMS	98,23	Lab-YCbCr-YIQ-HSV-UVL-GGB-HSL
	FCM	98,13	YIQ-UVL-GGB-HSL
	KMD	98,20	Lab-YIQ-GGB-HSL
Im0241	KMS	85,07	Lab-HSV-XYZ-UVL
	FCM	82,71	Gray-UVL
	KMD	84,79	Gray-RGB-Lab-UVL
ImO257	KMS	97,18	Lab-YCbCr
	FCM	97,13	Lab
	KMD	97,01	Lab
Im0454	KMS	93,73	YCbCr-GGB-HSL
	FCM	93,44	Gray-HSV-GGB
	KMD	93,03	GGB
Im0752	KMS	90,80	Lab
	FCM	77,13	Lab-GGB
	KMD	90,39	Lab
Im0774	KMS	96,34	Lab-YCbCr-YIQ-XYZ
	FCM	96,37	Lab-YCbCr-YIQ-XYZ
	KMD	96,31	Lab-YCbCr-YIQ-XYZ
Im0767	KMS	89,21	Gray-UVL
	FCM	89,06	Gray-UVL-HSL
	KMD	89,20	Gray-HSV-UVL
Im0821	KMS	82,21	GGB
	FCM	82,06	GGB
	KMD	82,17	GGB
Im0928	KMS	86,59	HSV
	FCM	61,31	Lab-HSL
	KMD	86,61	HSV-UVL

TABLE 4.1 – Résultat de segmentation obtenus avec les attributs de couleur.

4.3.2 Attributs de texture

Pour mener notre étude sur les attributs de texture, nous avons utilisé deux types d'attributs : G (Gabor) et H (Haralick).

Le tableau (4.4) montre les résultats de segmentation obtenus en utilisant les attributs de texture (Gabor, Haralick, Gabor+Haralick) appliqués sur les douze images (Images

Espaces	KMS	FCM	KMD	Somme
Gray	2	3	3	8
RGB	0	0	1	1
Lab	7	6	6	19
YCbCr	6	1	1	8
YIQ	3	1	2	6
HSV	5	2	3	10
Cmyk	0	0	0	0
XYZ	2	1	2	5
UVL	4	3	3	10
GGB	4	5	5	14
HSL	4	4	2	10

TABLE 4.2 – Le rang des espaces de couleur.

Méthodes	KMS	FCM	KMD
Moyenne	90.68	85.82	90.56

TABLE 4.3 – Moyenne des accuracy.

d'ajustement des paramètres), avec les trois méthodes de segmentation par classification.

Image	Texture	KMS	FCM	KMD	Image	Texture	KMS	FCM	KMD
Im0021	G	55,23	54,19	52,33	Im0454	G	76,22	74,59	71,72
	H	56,64	56,35	56,65		H	63,74	65,10	63,87
	G+H	55,08	54,14	51,81		G+H	77,52	75,97	72,90
Im0051	G	73,84	72,08	76,95	Im0752	G	71,18	72,06	70,64
	H	74,36	74,24	74,26		H	76,66	78,13	76,86
	G+H	73,82	73,03	76,60		G+H	74,43	74,00	74,37
Im0099	G	60,70	62,41	63,39	Im0767	G	78,19	81,52	77,70
	H	53,33	54,53	55,77		H	78,85	79,04	78,84
	G+H	60,68	62,62	64,21		G+H	80,35	82,87	78,69
Im0191	G	71,94	70,58	70,31	Im0774	G	74,48	79,85	71,41
	H	65,68	65,87	65,23		H	75,83	76,46	75,71
	G+H	72,49	71,00	72,03		G+H	84,73	81,84	71,78
Im0241	G	73,50	74,62	73,24	Im0821	G	79,60	67,98	68,48
	H	83,59	83,54	83,75		H	68,25	67,50	68,69
	G+H	81,06	79,01	77,87		G+H	78,16	72,54	76,89
Im0257	G	62,04	62,20	63,10	Im0928	G	68,19	71,31	61,92
	H	71,77	71,58	71,87		H	63,21	62,93	63,40
	G+H	63,77	64,63	64,06		G+H	64,50	70,58	53,39

TABLE 4.4 – Résultats de segmentation en utilisant les attributs de texture.

Ces résultats indiquent que pour certaines images, comme (im0241, im0767), donnent des résultats satisfaisants part rapport aux images avec des textures fines. Selon cette

étude, les attributs de Haralick donnent du meilleurs résultats par rapport aux attributs de Gabor.

4.3.3 Attributs de texture couleur

Dans cette section nous allons étudier les performances de la combinaison des attributs de texture et de couleur.

Le tableau (4.5) indique les combinaisons d'attributs utilisées (Couleur (C), Couleur+Gabor (C+G), Couleur+Haralick (C+H), Couleur+Gabor+Haralick (C+G+H)), et les résultats obtenus avec les trois méthodes de segmentation par classification. Les valeurs en gras représentent les meilleurs résultats.

Image	Attributs	KMS	FCM	KMD	Image	Attributs	KMS	FCM	KMD
Im0021	C	59,05	86,14	86,77	Im0454	C	93,74	93,44	93,04
	C+G	83,76	78,25	50,81		C+G	87,21	85,55	81,48
	C+H	86,42	85,63	86,49		C+H	94,29	93,98	94,08
	C+G+H	83,79	77,78	52,54		C+G+H	87,08	85,75	81,04
Im0051	C	83,80	67,68	83,80	Im0752	C	90,80	77,14	90,39
	C+G	74,65	72,58	80,08		C+G	73,10	75,31	78,64
	C+H	56,18	71,59	54,65		C+H	93,19	80,06	92,41
	C+G+H	74,31	72,93	74,87		C+G+H	75,82	76,46	72,83
Im0099	C	98,70	98,64	98,53	Im0767	C	89,22	89,07	89,21
	C+G	98,43	83,13	98,30		C+G	79,54	84,46	71,66
	C+H	98,66	98,53	98,64		C+H	82,36	86,16	86,17
	C+G+H	98,42	83,10	85,60		C+G+H	81,48	84,29	73,62
Im0191	C	98,23	98,14	98,21	Im0774	C	96,35	96,37	96,31
	C+G	97,34	87,74	96,38		C+G	96,72	95,89	96,11
	C+H	98,14	97,88	98,05		C+H	96,63	96,61	96,65
	C+G+H	96,95	85,12	96,12		C+G+H	96,40	95,48	96,36
Im0241	C	85,07	82,72	84,80	Im0821	C	82,22	82,06	82,17
	C+G	73,20	75,98	79,12		C+G	70,66	71,95	67,10
	C+H	88,84	87,02	90,59		C+H	82,87	81,84	81,16
	C+G+H	88,74	79,97	82,36		C+G+H	82,27	72,63	82,06
Im0257	C	97,18	97,13	97,01	Im0928	C	86,60	61,31	86,62
	C+G	65,28	65,01	64,69		C+G	65,99	64,66	62,40
	C+H	98,02	96,54	97,63		C+H	56,07	61,11	54,90
	C+G+H	65,97	69,23	65,57		C+G+H	64,80	65,75	56,58

TABLE 4.5 – Résultats de segmentation en utilisant les attributs de texture couleur.

A partir de ce tableau, nous avons remarqué des meilleurs résultats par rapport à ceux obtenus avec les attributs de texture uniquement. Néanmoins, dans l'ensemble, les résultats obtenus en combinant les deux attributs (couleur+Gabor, couleur+Gabor+haralick) n'ont pas surpassé de manière significative ceux obtenus avec la couleur.

Ces résultats nous conduisent à conclure que la couleur joue un rôle plus déterminant dans la segmentation d'images des DFU que la texture, du moins selon nos tests.

La figure (4.5) montre quelques résultats de segmentation par classification non supervisée (K-means).




FIGURE 4.5 – Segmentation d’images par K-means : (a) images originaux, (b) vérités terrains, (c) en utilisant les attributs de couleur, (d) en utilisant les attributs de texture (Haralick), (e) en utilisant les attributs de texture couleur (Haralick).

Nous avons remarqué dans cette figure que la meilleure segmentation a été donnée par le traitement où nous avons combiné la texture et la couleur (e) dans les images : im0241, im0454, im0752, et pour la dernière image (im0767) la meilleure segmentation est celle obtenue avec les attributs de couleur (c).

4.3.4 Résultats de segmentation semi-supervisée

Pour améliorer les résultats obtenus en segmentation des 8 images de tests par classification non supervisée, nous avons opté pour une segmentation semi-supervisée où nous avons intégré une interaction humaine sous forme de marques.

Le tableau (4.6) illustre les résultats de segmentation d’images par classification non supervisée (kmeans) et semi-supervisée (kmeans semi-supervisée). Nous avons comparé

les résultats de segmentation obtenus avec kmeans non supervisée avec tous les attributs (KMS (TA)) et avec les meilleurs attributs a savoir Lab, YCbCr, GGB, Haralick (KMS (MA)) et les résultats de segmentation de kmeans semi-supervisée avec les meilleurs attributs pour différents nombres de marques (3,3), (5,5), et (7,7).

Image	KMS (TA)	KMS (MA)	(3,3)	(5,5)	(7,7)
Im0422	62.42	59.87	96.76	93.21	95.24
Im0484	69.02	97.82	97.45	97.31	97.31
Im0568	85.46	93.26	93.32	93.72	95.10
Im0743	96.53	96.56	97.20	99.03	99.03
Im0804	68.23	68.49	93.41	95.94	96.57
Im0854	81.21	80.96	83.61	90.15	93.37
Im0914	74.75	79.19	95.03	95.39	95.39
Im0928	55.26	57.30	86.63	94.07	94.80

TABLE 4.6 – Résultats de segmentation par classification semi-supervisée.

Selon les résultats du tableau (4.6), nous constatons que les résultats obtenus par la combinaison des attributs les plus performants sont meilleurs que ceux obtenus avec la combinaison de tous les attributs. De plus, l’augmentation du nombre de marques faites par l’utilisateur en semi-supervisé semble contribuer à une amélioration des résultats.

4.3.5 Post-traitement

Pour améliorer significativement les résultats, nous avons intégré un post-traitement. Le tableau (4.7) illustre les résultats de segmentation après post-traitement.

Image	KMS (MA)	Marque (3,3)	Marque (5,5)	Marque (7,7)
Im0422	61.21	97.17	94.16	97.71
Im0484	98.46	97.13	97.80	97.80
Im0568	95.33	96.15	95.82	96.71
Im0743	96.42	99.12	99.12	99.12
Im0804	74.33	90.46	96.25	97.89
Im0854	73.96	83.69	90.41	95.21
Im0914	80.06	98.52	95.57	95.57
Im0928	81.16	81.16	97.32	97.27

TABLE 4.7 – Résultats de segmentation par classification semi-supervisée après post-traitement.

En conclu que les résultats obtenus après application de la morphologie mathématique sont bien améliorés, sauf dans certains cas (im0743, im0854 dans les résultats de K-means, et im0484, im0804, im0928 dans les résultats de marque (3,3)).

En intégrant l’interaction humaine, par application des marques, une amélioration significative des résultats a été observée. Cela est clairement démontré dans la figure

présentée ci-dessous, où l'on peut observer une nette différence dans les résultats obtenus (figures (4.6), (4.7), 4.8), (4.9))

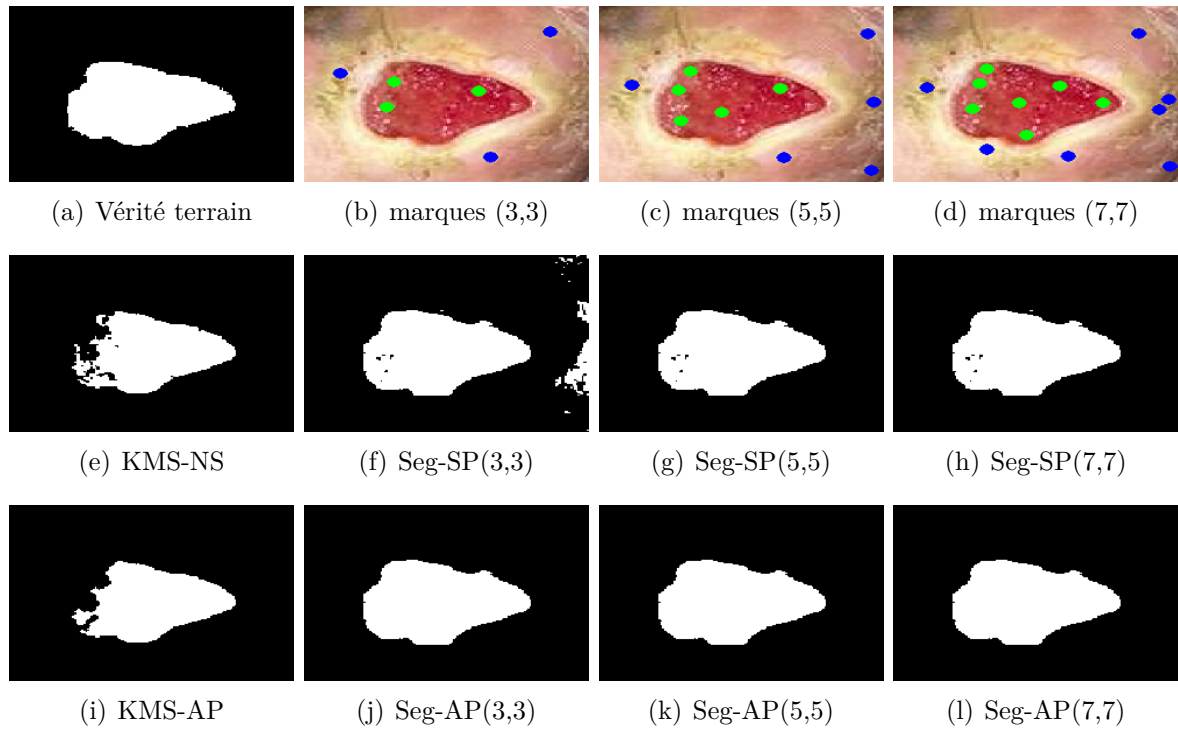


FIGURE 4.6 – Résultats visuels de segmentation interactive de l'image 0743 (NS :non supervisée, Seg-SP : sans post-traitement, Seg-AP : avec post-traitement)

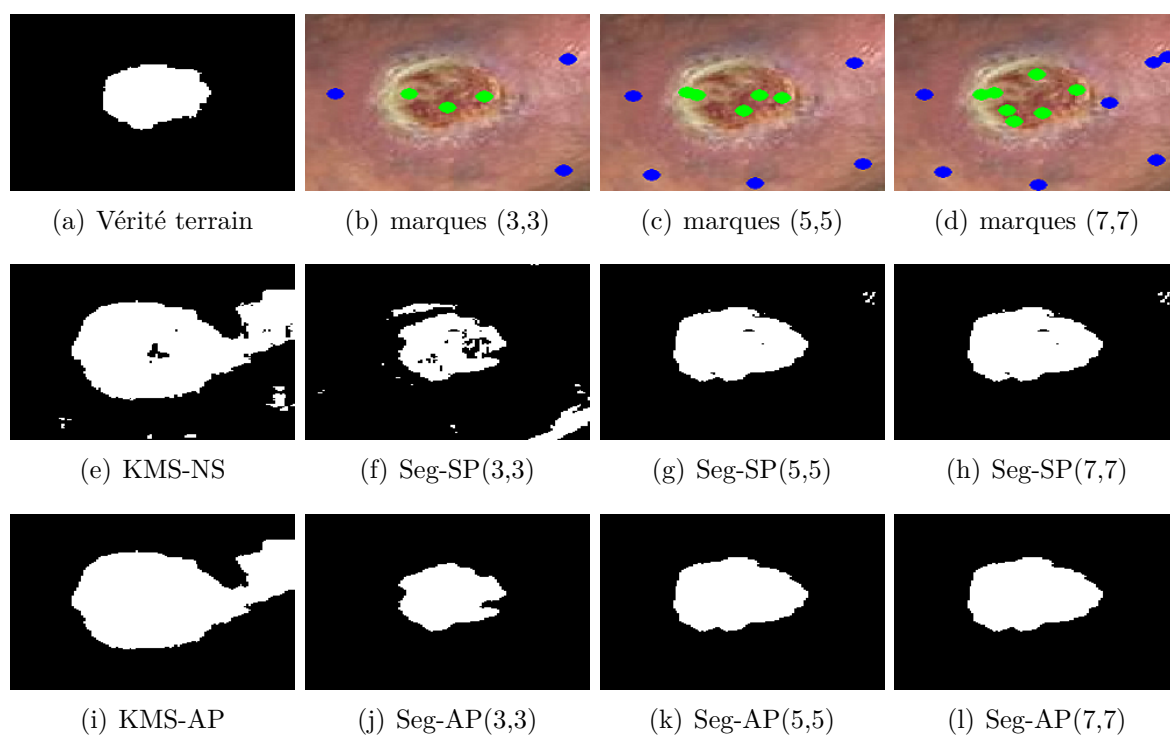


FIGURE 4.7 – Résultats visuels de segmentation interactive de l'image 0914 (NS :non supervisée, Seg-SP : sans post-traitement, Seg-AP : avec post-traitement)

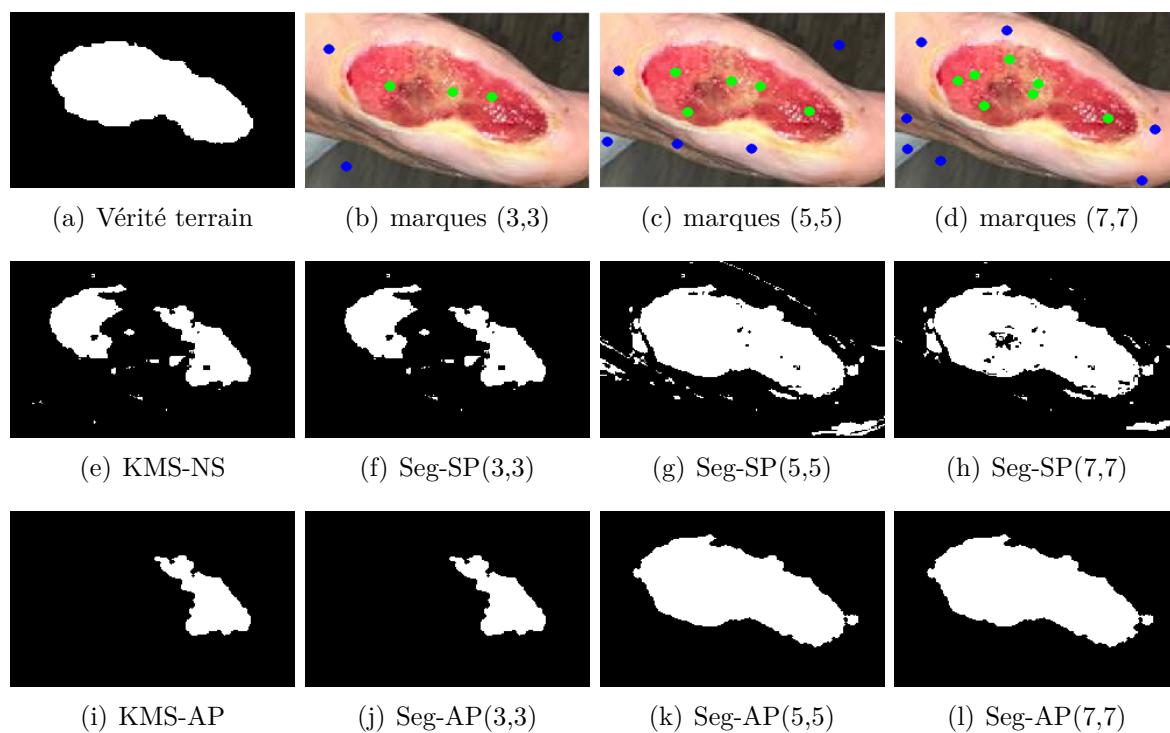


FIGURE 4.8 – Résultats visuels de segmentation interactive de l'image 0928 (NS :non supervisée, Seg-SP : sans post-traitement, Seg-AP : avec post-traitement)

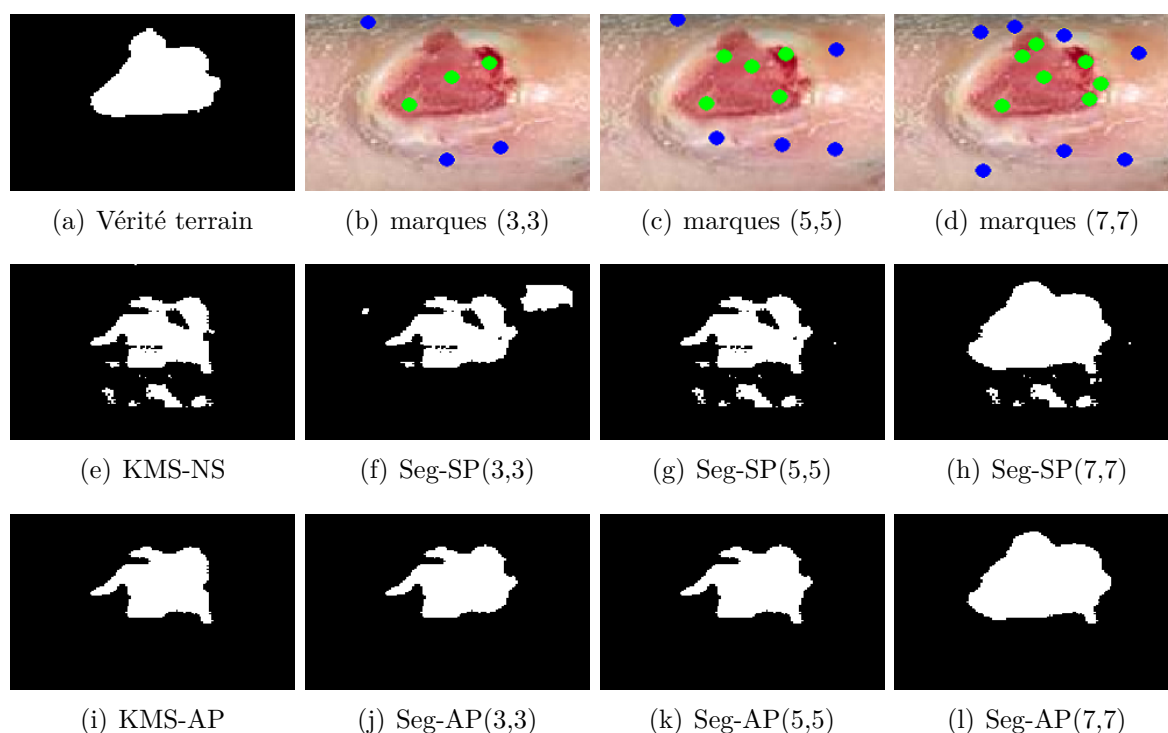


FIGURE 4.9 – Résultats visuels de segmentation interactive de l'image 0568 (NS :non supervisée, Seg-SP : sans post-traitement, Seg-AP : avec post-traitement)

Chaque fois que nous augmentons le nombre de marques, nous observons une amélioration notable des résultats. En intégrant un post-traitement à la segmentation obtenue, nous avons constaté une amélioration significative de la qualité de la segmentation.

4.4 Conclusion

Dans ce chapitre, nous avons présenté notre méthode de segmentation intitulée Segmentation interactive d'image par classification semi-supervisée : Application aux images médicales d'ulcères du pied diabétique. Cette approche se compose de quatre étapes principales : Acquisition et interaction de l'utilisateur, Pré-traitement, Extraction d'attributs, et Classification.

La première étape intègre l'intervention humaine dans le processus de segmentation. Cette interaction a permis d'améliorer significativement la précision des résultats, mettant en évidence l'importance de l'approche interactive pour l'analyse des images médicales. Dans la deuxième étape, divers pré-traitements sont utilisés pour optimiser la qualité des images acquises. Dans notre cas, un filtre gaussien a été appliqué pour réduire le bruit. La troisième étape se concentre sur l'extraction d'attributs de texture et de couleur. Nous avons étudié des attributs de couleur tels que Lab, GGB, HSL, HSV, et Gray, ainsi que des attributs de texture comme ceux définis par Haralick. Ces attributs ont été sélectionnés pour leur pertinence spécifique à la segmentation des images médicales, notamment celles liées aux ulcères du pied diabétique. Enfin, la quatrième étape consiste en l'application de méthodes de classification non supervisées et semi-supervisées. Parmi

celles-ci, l'algorithme K-means s'est avéré le plus performant pour notre étude de cas.

CONCLUSION GÉNÉRALE ET PERSPECTIVES

Dans le cadre général de ce travail, nous avons pu identifier la région d'intérêt sur plusieurs images liées aux ulcères du pied diabétique (DFU) en utilisant deux types de segmentation par classification (non supervisée et semi-supervisée) avec certaines méthodes de segmentation par classification, ou nous avons employé différents attributs couleur et texture ou les deux à la fois.

Nous avons plus particulièrement déterminé les meilleurs espaces de couleur (Lab, GGB, HSV, HSL, UVL) et de texture (Haralick), ainsi que la meilleure segmentation (segmentation par classification semi-supervisée) dans le cadre de la segmentation des images DFU en utilisant l'approche de segmentation par classification.

L'interaction humaine intégrée dans le processus de segmentation par classification semi-supervisée joue un rôle important dans l'amélioration de la précision de la segmentation.

Ce mémoire explore l'approche de segmentation interactive par classification semi-supervisée pour les images d'ulcères du pied diabétique (DFU), visant à améliorer la précision du diagnostic et de la prise en charge clinique. En intégrant l'intervention humaine dans le processus de segmentation, cette méthode augmente les défis de la variabilité des caractéristiques cliniques et visuelles des ulcères du pied diabétique, offrant ainsi des résultats plus précis par rapport aux méthodes de segmentation par classification non supervisées. Les résultats expérimentaux ont montré une nette amélioration de la précision de la segmentation.

Les résultats montrent une amélioration significative de la qualité des images après les étapes de pré-traitement et de post-traitement. Les images capturées avec les caméras haute définition ont fourni des données de haute qualité, caractérisées par une résolution suffisante pour une analyse détaillée. Le pré-traitement a considérablement réduit le bruit et amélioré le contraste, préparant ainsi les images pour la segmentation. Cette dernière a permis d'identifier les objets d'intérêt. Le post-traitement a ensuite affiné les résultats en corrigeant les erreurs de segmentation et en lissant les contours, consolidant ainsi les régions segmentées pour une représentation plus précise et cohérente des données.

En conclusion, ce mémoire contribue significativement à l'avancement des technologies de traitement d'images médicales en proposant une approche adaptable et efficace pour mieux répondre aux besoins cliniques spécifiques des patients atteints de DFU.

Perspectives

Pour des travaux futurs, nous pouvons donner les perspectives suivantes :

- L'utilisation d'autres méthodes de segmentation par classification non supervisées (DBSCAN, Classification spectrale, ...) et semi-supervisées (Fuzzy C-means, Hiérarchique, DBSCAN, ...).
- L'amélioration des images en utilisant d'autres types de filtrage et d'autres post-traitements.
- L'utilisation d'autre attributs de couleur (CMY, IST, LCH, ...), de texture (LBP, ...) et ceux de la forme ... etc.

Bibliographie

- [1] S. K. Das, P. Roy, P. Singh, M. Diwakar, V. Singh, A. Maurya, S. Kumar, S. Kadry, and J. Kim, “Diabetic foot ulcer identification : a review,” *Diagnostics*, vol. 13, no. 12, p. 1998, 2023.
- [2] N. Rabia, *Revue des méthodes de segmentation d’images texturées : Cas des images couleur*. PhD thesis, Université Mouloud Mammeri, 2011.
- [3] N. Vandenbroucke and L. Macaire, “Les espaces couleurs,” 2005.
- [4] O. Lezoray, *Segmentation d’images par morphologie mathématique et classification de données par réseaux de neurones : Application à la classification de cellules en cytologie des séreuses*. PhD thesis, Université de Caen Basse-Normandie, 2000.
- [5] B. Karima and D. Dihia, “Mémoire de fin d’étude de master académique,”
- [6] D. Attia, *Segmentation d’images par combinaison adaptative couleur-texture et classification de pixels : Applications à la caractérisation de l’environnement de réception de signaux GNSS*. PhD thesis, Université de Technologie de Belfort-Montbéliard, 2013.
- [7] M. Hanifi, *Extraction de caractéristiques de texture pour la classification d’images satellites*. PhD thesis, Toulouse 3, 2009.
- [8] J.-H. Sublemontier, *Classification non supervisée : de la multiplicité des données à la multiplicité des analyses*. PhD thesis, Université d’Orléans, 2012.
- [9] A. McAndrew, “An introduction to digital image processing with matlab notes for scm2511 image processing,” *School of Computer Science and Mathematics, Victoria University of Technology*, vol. 264, no. 1, pp. 1–264, 2004.
- [10] C. Solomon and T. Breckon, *Fundamentals of Digital Image Processing : A practical approach with examples in Matlab*. John Wiley & Sons, 2011.
- [11] V. Blanchette and M. Brousseau-Foley, “Prise en charge multidisciplinaire de l’infection de l’ulcération plantaire diabétique,” *La Revue de Médecine Interne*, vol. 42, no. 3, pp. 193–201, 2021.
- [12] M. Tenenbaum, A. Bonnefond, P. Froguel, and A. Abderrahmani, “Physiopathologie du diabète,” *Revue Francophone des Laboratoires*, vol. 2018, no. 502, pp. 26–32, 2018.
- [13] N. Rania, H. Douzi, L. Yves, and T. Sylvie, “Semantic segmentation of diabetic foot ulcer images : dealing with small dataset in dl approaches,” in *Image and Signal Processing : 9th International Conference, ICISP 2020, Marrakesh, Morocco, June 4–6, 2020, Proceedings 9*, pp. 162–169, Springer, 2020.
- [14] M. H. Yap, C. Kendrick, N. D. Reeves, M. Goyal, J. M. Pappachan, and B. Cassidy, “Development of diabetic foot ulcer datasets : an overview,” *Diabetic Foot Ulcers Grand Challenge*, pp. 1–18, 2021.

-
- [15] D. Malgrange, “Physiopathologie du pied diabétique,” *La revue de médecine interne*, vol. 29, pp. S231–S237, 2008.
- [16] G. Mahé and V. Jaquinandi, “Artériopathie des membres inférieurs athéromateuse : diagnostic,” *La Presse Médicale*, vol. 47, no. 1, pp. 47–55, 2018.
- [17] J. Boukhris, Y. Benyass, M. Boussaidane, J. Mekkaoui, B. Chafry, D. Benchebba, S. Bouabid, and M. Boussouga, “Infection du pied diabétique : Du diagnostic a la prise en charge (revue de la littérature),” *Revue Marocaine de Chirurgie Orthopédique et Traumatologique*, vol. 75, pp. 9–15, 2018.
- [18] G. H. Van, “Le pied diabétique,” *Revue du rhumatisme monographies*, vol. 81, no. 3, pp. 192–197, 2014.
- [19] L. Wang, P. C. Pedersen, D. M. Strong, B. Tulu, E. Agu, and R. Ignatz, “Smartphone-based wound assessment system for patients with diabetes,” *IEEE Transactions on Biomedical Engineering*, vol. 62, no. 2, pp. 477–488, 2014.
- [20] M. H. Yap, C.-C. Ng, K. Chatwin, C. A. Abbott, F. L. Bowling, A. J. Boulton, and N. D. Reeves, “Computer vision algorithms in the detection of diabetic foot ulceration : a new paradigm for diabetic foot care?,” *Journal of diabetes science and technology*, vol. 10, no. 2, pp. 612–613, 2016.
- [21] A. Heras-Tang, D. Valdés-Santiago, Á. M. León-Mecías, M. L. Baguer Díaz-Romañach, and J. A. Mesejo-Chiong, “Diabetic foot ulcer segmentation using logistic regression, dbscan clustering and mathematical morphology operators,” *ELCVIA : Electronic Letters on Computer Vision and Image Analysis*, vol. 21, no. 2, pp. 22–39, 2022.
- [22] L. Nacerdine, *Segmentation d’images avec le deep learning*. PhD thesis, Université Mouloud Mammeri, 2018.
- [23] M. Sandeli, “Traitement d’images par des approches bio-inspirées application à la segmentation d’images,” *Université Constantine*, vol. 2, p. s1, 2014.
- [24] A. Hammouche, *Systèmes multi-Agents appliquées en segmentation d’images*. PhD thesis, Université Mouloud Mammeri, 2008.
- [25] X. Zheng, Q. Lei, R. Yao, Y. Gong, and Q. Yin, “Image segmentation based on adaptive k-means algorithm,” *EURASIP Journal on Image and Video Processing*, vol. 2018, no. 1, pp. 1–10, 2018.
- [26] B. Meriem and L. Boussad, *Segmentation D’Image Couleur Basée Les Espaces Colorimétriques : Méthode D’Ohlander, Price & Reddy*. PhD thesis, Université Mouloud Mammeri, 2008.
- [27] A. Bougrine, *Analyse d’images thermiques de la voûte plantaire : Application au diagnostic du pied diabétique*. PhD thesis, Université d’Orléans, 2020.
- [28] J. Poulin, *De la médecine à la géologie—visualisation des modèles physiques par tomomodensitométrie*. Institut National de la Recherche Scientifique (Canada), 2008.
- [29] O. Abdelli, *Segmentation d’images par seuillage d’histogrammes bidimensionnels*. PhD thesis, Université Mouloud Mammeri, 2011.
- [30] A. Dupas, *Opérations et algorithmes pour la segmentation topologique d’images 3D*. PhD thesis, Université de Poitiers, 2009.
-

-
- [31] M. Hayet, “Une nouvelle approche de seuillage hiérarchique pour la segmentation d’image,”
- [32] A. mohamed Amine, E. Zakaria, and A. Abdelmalek, “Expérimentations sur la classification non supervisée de textes arabes,”
- [33] Y. K. Dubey, M. M. Mushrif, *et al.*, “Fcm clustering algorithms for segmentation of brain mr images,” *Advances in Fuzzy Systems*, vol. 2016, 2016.
- [34] T. Q. Nguyen, *Apprentissage automatique non supervisé pour la détection de trafics illégitimes*. PhD thesis, Université Paul Sabatier-Toulouse III, 2023.
- [35] M. Boubou, *Contribution aux méthodes de classification non supervisée via des approches prétopologiques et d’agrégation d’opinions*. PhD thesis, Université Claude Bernard-Lyon I, 2007.
- [36] D. FOFI and J. S. El Mustapha MOUADDIB, “Décodage d’un motif structurant codé par la couleur,” in *Colloque du Groupe de Recherche sur le Traitement du Signal et des Images (GRETSI’2001), Toulouse (France)*, 2001.
- [37] W. Boussellaa, A. Zahour, B. Taconet, A. Benabdelhafid, and A. Alimi, “Méthode hybride de séparation avant/arrière-plan pour la restauration des manuscrits arabes anciens couleur,” in *Actes du 9ème Colloque International Francophone sur l’Écrit et le Document*, pp. 205–210, SDN06, 2006.
- [38] L. Boussaid, A. MTIBAA, M. ABID, and M. PAINDAVOINE, “Conception d’un descripteur de contenu vidéo sur une architecture à base de fpga virtex,” *Journées Francophones sur l’Adéquation Algorithme Architecture (JFAAA’05), Dijon France*, 2005.
- [39] S. Ouatara, *Stratégies de segmentation d’images multi-composantes par analyse d’histogramme multidimensionnels*. PhD thesis, Thèse de doctorat, école doctorale d’Angers STIM, France, 2009.
- [40] N. Vandembroucke, *Segmentation d’images couleur par classification de pixels dans des espaces d’attributs colorimétriques adaptés : application à l’analyse d’images de football*. PhD thesis, Lille 1, 2000.
- [41] B. Abd and T. Hicham, “Segmentation de la couleur de peau par seuillage selon différents espaces de couleur,”
- [42] O. Lezoray, A. Elmoataz, H. Cardot, G. Gougeon, M. Lecluse, H. Elie, and M. Revenu, “Segmentation d’images couleur : application à la cytologie des séreuses en vue d’un tri informatique cellulaire,” in *11e Congrès Reconnaissance des formes et intelligence artificielle (RFIA)*, vol. 2, pp. 287–295, 1998.
- [43] L. Brun and J. P. Braquelaire, “Quantification de couleurs par partition dynamique.,”
- [44] M. Goossens and M. Jouhet, “Utiliser la couleur avec la tex2,”
- [45] R. B. Hegde, K. Prasad, H. Hebbar, and B. M. K. Singh, “Development of a robust algorithm for detection of nuclei of white blood cells in peripheral blood smear images,” *Multimedia Tools and Applications*, vol. 78, pp. 17879–17898, 2019.
- [46] G. Aghiles and S. Samira, *Contribution de l’approche LBP à la classification des images multispectrales. Application aux données TM de la région du Hoggar*. PhD thesis, Université Mouloud Mammeri, 2014.
-

-
- [47] M. Keivani, J. Mazloun, E. Sedaghatfar, and M. B. Tavakoli, “Automated analysis of leaf shape, texture, and color features for plant classification.,” *TRAITEMENT du Signal*, vol. 37, no. 1, pp. 17–28, 2020.
- [48] A. Moussa, M. Maouene, I. Qazi, O. Alata, J. Burie, and A. Sbihi, “Classification d’images couleur texturées,” in *10e CARI-Colloque Africain sur la Recherche en Informatique*, 2010.
- [49] L. YOUSFI, *Les algorithmes génétiques pour la caractérisation du tissu osseux sur radiographies osseuses*. PhD thesis, 2019.
- [50] B. Karima and D. Dihia, *Recherche d’image par le contenu*. PhD thesis, Université Mouloud Mammeri, 2018.
- [51] R. M. Haralick, K. Shanmugam, and I. H. Dinstein, “Textural features for image classification,” *IEEE Transactions on systems, man, and cybernetics*, no. 6, pp. 610–621, 1973.
- [52] B. Mathieu, *Segmentation interactive multiclasse d’images par classification de superpixels et optimisation dans un graphe de facteurs*. PhD thesis, Université Paul Sabatier-Toulouse III, 2017.
- [53] A. Top, G. Hamarneh, and R. Abugharbieh, “Active learning for interactive 3d image segmentation,” in *Medical Image Computing and Computer-Assisted Intervention—MICCAI 2011 : 14th International Conference, Toronto, Canada, September 18-22, 2011, Proceedings, Part III 14*, pp. 603–610, Springer, 2011.
- [54] F. Zhao and X. Xie, “An overview of interactive medical image segmentation,” *Annals of the BMVA*, vol. 2013, no. 7, pp. 1–22, 2013.
- [55] T. Mary-Huard, *Réduction de la dimension et sélection de modèles en classification supervisée*. PhD thesis, Université Paris Sud-Paris 11, 2006.
- [56] B. Nour El Houda, *Identification des appareils électriques basée sur le classificateur KNN combiné avec la règle de vote*. PhD thesis, Faculté des Sciences et Technologies, 2020.
- [57] A. C. E. BENNIA, *La recherche et la décontamination de séquences contaminées dans un assemblage De Novo par un modèle basé sur la classification supervisée*. PhD thesis, Université de Bordj Bou Arreridj Faculty of Mathematics and Computer Science, 2021.
- [58] O.-H. NOUKAS, *Etude Comparative des CNNs et de L’algorithme K-NN en mammographie*. PhD thesis, Université Ibn Khaldoun, 2023.
- [59] Z. Guellil and L. Zaoui, “Proposition d’une solution au problème d’initialisation cas du k-means.,” in *CIIA*, 2009.
- [60] N. Ouvarab, Y. Smara, and J.-P. Rasson, “Utilisation de méthodes de classification hiérarchique pour une classification supervisée d’images satellitaires,” in *Dix-septième colloque GRETSI, Vannes*, pp. 13–17, 1999.
- [61] C. Wang, W. Chen, P. Yin, and J. Wang, “Semi-supervised clustering using incomplete prior knowledge,” in *Computational Science—ICCS 2007 : 7th International Conference, Beijing, China, May 27-30, 2007, Proceedings, Part I 7*, pp. 192–195, Springer, 2007.
-

- [62] R. Battiti, D. T. Truong, *et al.*, “A survey of semi-supervised clustering algorithms : from a priori scheme to interactive scheme and open issues,” 2013.
- [63] A. George, “Efficient high dimension data clustering using constraint-partitioning k-means algorithm.,” *Int. Arab J. Inf. Technol.*, vol. 10, no. 5, pp. 467–476, 2013.
- [64] M. Saida, *Etude comparative des performances des classifieurs Support Vector Machines (SVM) et Fuzzy C-Means (FCM). Application à la segmentation d’images texturées*. PhD thesis, Université Mouloud Mammeri, 2017.
- [65] J. Macqueen, “Some methods for classification and analysis of multivariate observations,” in *Proceedings of 5-th Berkeley Symposium on Mathematical Statistics and Probability/University of California Press*, 1967.
- [66] M. Soltani, *Partitionnement des images hyperspectrales de grande dimension spatiale par propagation d’affinité*. PhD thesis, Université de Rennes, 2014.
- [67] S. Basu, A. Banerjee, and R. J. Mooney, “Semi-supervised clustering by seeding,” in *Proceedings of the nineteenth international conference on machine learning*, pp. 27–34, 2002.
- [68] H. BENRAZEK, *CLASSIFICATION DU TRAFIC INTERNET A L’AIDE DE L’APPRENTISSAGE AUTOMATIQUE*.

Résumé

La segmentation interactive d'images est un processus permettant à l'utilisateur de délimiter et d'identifier des régions spécifiques dans une image, offrant ainsi un contrôle précis sur le résultat final. Contrairement à la segmentation non supervisée, qui cherche à séparer les régions d'intérêt sans intervention humaine, la segmentation interactive implique une interaction directe avec l'utilisateur pour guider le processus de segmentation. Cette méthode est largement utilisée dans divers domaines tels que la vision par ordinateur, l'analyse d'images médicales, la cartographie et la télédétection, et d'autres domaines où une segmentation précise est nécessaire. Dans ce travail, nous présenterons une méthode de segmentation interactive basée sur la classification des pixels. Cette approche sera appliquée spécifiquement aux images médicales associées aux ulcères du pied diabétique, visant à fournir une segmentation précise et adaptée aux besoins cliniques.

Résumé

La segmentation interactive d'images est un processus permettant à l'utilisateur de délimiter et d'identifier des régions spécifiques dans une image, offrant ainsi un contrôle précis sur le résultat final. Contrairement à la segmentation non supervisée, qui cherche à séparer les régions d'intérêt sans intervention humaine, la segmentation interactive implique une interaction directe avec l'utilisateur pour guider le processus de segmentation. Cette méthode est largement utilisée dans divers domaines tels que la vision par ordinateur, l'analyse d'images médicales, la cartographie et la télédétection, et d'autres domaines où une segmentation précise est nécessaire. Dans ce travail, nous présenterons une méthode de segmentation interactive basée sur la classification des pixels. Cette approche sera appliquée spécifiquement aux images médicales associées aux ulcères du pied diabétique, visant à fournir une segmentation précise et adaptée aux besoins cliniques.

Mots clés : Segmentation d'images, DFU, classification semi-supervisée, traitement d'images.