

REPUBLIQUE ALGERIENNE DEMOCRATIQUE ET POPULAIRE
MINISTERE DE L'ENSEIGNEMENT SUPERIEUR ET DE LA RECHERCHE
SCIENTIFIQUE

UNIVERSITE MOHAMED BOUDIAF - M'SILA



FACULTE MATHÉMATIQUE ET INFORMATIQUE

DEPARTEMENT D'INFORMATIQUE

N° :



MEMOIRE DE FIN D'ETUDE

Présenté pour l'obtention du Diplôme MASTER

Domaine : Mathématiques et Informatique

Filière : Informatique

Option : Système d'Information et Génie Logiciel

Présenté par

- Bakhti Smail - Boudjellal Hocine

Thème

*La segmentation des image
par la méthode de classification
"Fuzzy C-Means" FCM*

Devant le jury :

Benouis Mohamed

Université de M'sila

Président

Mokhtari Rabah

Université de M'sila

Encadreur

Amri Said

Université de M'sila

Co-Encadreur

Yagoubi Rached

Université de M'sila

Examineur

Année universitaire : 2021/2022

Remerciements

Nous adressons en premier lieu notre reconnaissance à notre DIEU tout puissant, de m'avoir permis d'arriver là, car sans lui rien n'est possible.

Nous tenons tout d'abord à remercier Mr Mokhtari Rabah et Amri Said nos encadreurs de mémoire, pour ses encadrements, ses suivis et ses conseils lors de la réalisation de notre mémoire.

Nous tenons ensuite à remercier tous nos professeurs et enseignants de département d'informatique qui ont contribué à notre formation.

Nous souhaitons aussi remercier mesdames et messieurs les membres du jury pour leur précieux temps accordé à l'étude de notre mémoire.

Enfin nous remercions tous ceux qui ont contribué de près ou de loin à l'aboutissement de ce travail.

Table des matières

Introduction générale.....	1
Chapitre I : Généralité sur le traitement d'image	
1.Introduction	3
2.Définition d'une image :	3
3.Image numérique :(numérisée) :.....	3
4.Caractéristiques d'une image numérique :	4
4.1. Pixel :	4
4.2. La résolution.....	5
4.3. Dimension :	5
4.4. La texture.....	5
4.5. Bruit.....	5
4.6.La luminance	6
4.7. Contours et textures.....	6
4.8. Histogramme	6
4.9. Le contraste	7
5. Types d'images	7
5.1. Images binaires (en noir et blanc)	7
5.2. Images à niveaux de gris (Monochromes)	8
5.3. Images en couleurs (Polychromes)	9
6. Qualité de l'image numérique	9
7. Images bitmap et images vectorielles	9
8. Système de traitement d'image	10
8.1. Acquisition et numérisation :	10
8.2. Visualisation	10
9. Traitement numérique des images	11
9.1. Filtrage numérique	11
9.1.1. Filtres linéaires	12
9.1.2. Filtres non linéaire	13
9.2. Domaines d'application	14
10. Conclusion	15
Chapitre II : Les approches de la segmentation d'images	
1. Introduction :	16
2. Segmentation d'image :	17
2.1. Définition de la segmentation :.....	17
2.2. Définition formelle de la segmentation.....	18
2.3. Le choix d'une technique de segmentation:	18
2.4. Objectifs de la segmentation :	18
3. Les stratégies de segmentation :	19
3.1. Les stratégies scalaires :	19
3.2. Les stratégies marginales :	20
3.3. Les stratégies vectorielles :	20
3.4. Les Stratégie hybride :	21
4. Les méthodes de segmentation :	21
4.1. Approche Contour :.....	21
4.1.1. Le processus « classique » de détection de contours :	21
4.1.2. Les méthodes d'approche Contour :	22
4.1.2.1 Méthodes dérivatives :	22
4.1.2.2. Méthodes analytiques	25
4.1.2.3. Méthodes déformables.....	25
4.1.2.4. Les limites de segmentation par contour.....	26

4.2. Approche région.....	26
4.2.1. Croissance de région (région growing) :	27
4.2.2. Segmentation par fusion de régions (Merge)	28
4.2.3. Segmentation par division de régions (Split)	28
4.2.4. Segmentation par division-fusion (Split and Merge).....	28
4.3. Segmentation par seuillage.....	29
4.3.1. Définition du seuillage	29
4.3.2. Seuillage globale.....	30
4.3.3. Seuillage locale	30
5. Les critères d'évaluation :	31
5.1. Evaluation de segmentation en contour :	31
5.2. Evaluation de segmentation en région :	33
5.2.1. Evaluation non-supervisée :	33
5.2.2. Evaluation supervisée :	33
6. Conclusion :	34

Chapitre III : La méthode de classification "Fuzzy C-Means"

Partie 1 : La logique floue

1. Introduction	35
2. Historique	35
3. Théorie des sous-ensembles flous.....	36
3.1. Notion d'ensemble et de sous-ensemble flou.....	36
3.2. Valeur d'appartenance	37
3.3. Fonctions d'appartenance.....	37
3.4. Opérations sur les ensembles flous	38
3.4.1. Intersection	38
3.4.2. Union	38
3.4.3. Complément	39
3.4.4. Egalité.....	39
3.4.5. Inclusion.....	39
3.5. Distance entre deux sous-ensembles flous	39
3.5.1. Distance de Hamming.....	40
3.5.2. Distance Euclidienne.....	40
4. Schéma d'une commande floue.....	40
4.1. Fuzzification	41
4.2. Défuzzification.....	41
4.3. Mécanisme d'inférence.....	41
4.3.1. Proposition floue.....	41
4.3.2. Règle floue.....	42
5. Applications du flou	42
5.1. Logique floue et autres techniques	42

Partie 2 : La méthode de classification k-means

1. Introduction.....	43
2. Historique sur k-means.....	43
3. Présentation de k-means	44
4. k-means et la segmentation d'images	44
5. Fonctionnement générale K-means	45
6. Algorithme de k-means	45
7. Intérêt et Limitation de k-means	46
7.1. Intérêt de k-means	46
7.2. Limitation de k-means	46
8. Domaines d'applications	46
9. Exemples sur k-means	46

Partie 3 : la méthode de classification "Fuzzy C-Means" ou FCM

1. Introduction.....	47
2. Historique.....	47
3. Algorithme de classification floue.....	48
3.1. L'algorithme C-moyennes floues ("Fuzzy C-Means" ou FCM)	48
3.2. Fonctionnement de l'algorithme FCM	48
3.3. Présentation de l'algorithme FCM	48
3.4. Déroulement de FCM.....	49
4. Domaine d'application.....	50
5. L'algorithme FCM appliqué a la segmentation d'images.....	50
6. Intérêt, limitations de FCM.....	51
6.1. Avantages.....	51
6.2. Limitations.....	51
7. Exemple sur FCM.....	51
Conclusion.....	52

Chapitre IV : Tests et résultats

1. Introduction.....	53
2. Système de travail.....	53
3. Algorithme	55
4. Pseudo-code.....	56
5. Présentation et implémentation du système de segmentation d'image.....	57
6. Présentation de l'application.....	58
6.1. Interface principale.....	58
6.2. Différentes fonctionnalités de l'application.....	58
6.2.1. Chargement de l'image.....	58
6.2.2. Histogrammes de l'image.....	59
6.2.3. Choix de paramètres.....	59
6.2.4. Lancement de l'algorithme FCM.....	60
7. Résultat de FCM.....	60
8. Conclusion.....	62
Conclusion générale.....	64
Bibliographie	65

Liste des figures

Figure I-1:	<i>Représentation d'image numérique.....</i>	4
Figure I-2:	<i>Groupe de pixel formant la lettre A</i>	4
Figure I-3:	<i>Image sans bruit</i>	5
Figure I-4:	<i>Image avec bruit</i>	5
Figure I-5:	<i>Contour d'une image</i>	6
Figure I-6:	<i>Image avec histogramme.....</i>	7
Figure I-7:	<i>Image binaire.</i>	8
Figure I-8:	<i>Image Monochrome (256 couleurs)</i>	8
Figure I-9:	<i>Image polychrome (65536 couleurs)</i>	9
Figure I-10:	<i>Composition d'un système de traitement numérique.....</i>	10
Figure I-11:	<i>Masque du filtre.....</i>	12
Figure I-12:	<i>Masque de filtre.....</i>	12
Figure I-13:	<i>Principe du filtre médian</i>	13
Figure I-14:	<i>Principe du filtre maximum</i>	14
Figure I-15:	<i>Principe du filtre minimum.</i>	14
Figure II.1 :	<i>Analyse de l'image.....</i>	16
Figure II-2:	<i>Exemple de segmentation d'image</i>	17
Figure II.3:	<i>stratégie scalaire</i>	19
Figure II.4 :	<i>Les stratégies marginales.....</i>	20
Figure II.5 :	<i>Les stratégies vectorielles.....</i>	20
Figure II.6 :	<i>le processus classique de détecteur de contours</i>	21
Figure II-7:	<i>Contour et ses dérivées.....</i>	22
Figure II-8:	<i>Détection de contour par les différents filtres</i>	24
Figure II-9:	<i>Image originale (à gauche), contour détecté par le Laplacien</i>	24
Figure II-10:	<i>Croissance progressive des régions</i>	27
Figure II-11:	<i>Décompositions successives des blocs</i>	28
Figure II-12 :	<i>Agrégation itérative des blocs similaires au bloc 1.....</i>	29

Figure II-13:	<i>Seuillage simple d'un histogramme.</i>	29
Figure II-14:	<i>Seuillage multiple d'un histogramme.....</i>	30
Figure III.1:	<i>Comparaison d'un ensemble classique et d'un ensemble flou.....</i>	37
Figure III.2 :	<i>fonction caractéristique</i>	38
Figure III.3 :	<i>fonction d'appartenance</i>	38
Figure III.4 :	<i>Représentation du schéma d'une commande floue</i>	40
Figure III.5 :	<i>Comparaison de la logique floue et d'autres techniques</i>	43
Figure III.6 :	<i>Principe de fonctionnement général de k-means</i>	44
Figure III.7 :	<i>Démonstration des quatre étapes de k-means avec (K=3)</i>	45
Figure III.8 :	<i>Image originale, application k-means avec K=2 et K= 3</i>	46
Figure III.9 :	<i>Exemple de classification (classes floues)</i>	47
Figure III.10 :	<i>Image originale, application FCM avec K=2 et K= 3</i>	51
Figure IV. 1 :	<i>L'interface de MATLAB</i>	54
Figure IV.2:	<i>Le script de Matlab</i>	55
Figure IV. 3 :	<i>Schéma général de l'application</i>	57
Figure IV.4 :	<i>Interface principale de l'application.....</i>	58
Figure IV.5 :	<i>Chargement d'une image.....</i>	58
Figure IV.6 :	<i>histogramme de l'image (indique la valeur probable de k en nombre de pics)</i>	59
Figure IV.7 :	<i>Chargement des paramètres</i>	59
Figure IV.8 :	<i>lancement de FCM</i>	60
Figure IV.9 :	<i>Résultat de segmentation avec FCM(Test1)</i>	60
Figure IV.10	<i>Résultat de segmentation avec FCM (Test2)</i>	61
Figure IV.11	<i>Résultat de segmentation avec FCM (Test3)</i>	61

Liste des tableaux

Tableau II .1:	<i>Principaux masques de calcul de gradient</i>	23
-----------------------	---	----

Introduction générale

Avec la parole, l'image constitue l'un des moyens les plus efficaces pour communiquer avec autrui, chacun peut analyser l'image à sa manière, pour en dégager une impression et en extraire des informations précises.

Durant ces dernières années, l'informatique s'est affirmée comme une nouvelle technologie majeure, les progrès constants des techniques mathématiques et des moyens informatiques de calcul ont eu de nombreuses représentations sur les avancées et les applications dans les domaines de l'acoustique, de la médecine, des télécommunications et de l'imagerie, etc.

De ce fait, le traitement d'images est l'ensemble des méthodes et techniques s'exerçant sur celles-ci, dans le but de rendre cette opération possible, plus simple, plus efficace et plus agréable, d'améliorer l'aspect visuel de l'image et d'en extraire des informations jugées pertinentes, l'observation puis l'analyse d'une image est une opération simple pour le cerveau humain, pourtant, elle semble très difficile à modéliser mathématiquement et à imiter par des outils informatiques et automatiques. Pourquoi ? Parce que comme cela a été expliqué dans la théorie de la forme, l'analyse visuelle des formes par le cerveau s'effectue à un niveau global et non local comme tendrait à le faire un système automatique. En effet, lorsque l'on traite informatiquement une image, la première donnée à laquelle on a accès est le niveau de gris ou la couleur d'un pixel, la difficulté est donc de remonter de cette information très «bas niveau» vers une information plus riche.

La transformation apportée à cette information est obtenue par le passage par trois étapes essentielles qui sont: le prétraitement, la segmentation et l'interprétation.

C'est à cette difficulté que l'on est directement confronté lorsque l'on a affaire à un problème de segmentation.

La segmentation d'image est définie comme une division de l'image en régions, qui sont des ensembles nets (par opposition aux ensembles flous), il y a un choix univoque pour chaque site d'appartenir ou non à chaque région. Mais un pixel dans «le centre» d'une région homogène, appartient certainement beaucoup plus à cette région que des pixels agglomérés à la fin d'une croissance de régions par exemple, et un pixel près d'un contour n'est certainement pas dans la même région qu'un pixel placé de l'autre côté de ce contour. Afin de modéliser cette connaissance, nous proposons de construire des régions qui ne sont plus des ensembles nets, mais des ensembles flous, avec pour chaque site de l'image un degré d'appartenance à chaque région.

Le clustering, ou segmentation, est une opération qui a pour but de séparer différentes zones homogènes d'une image, afin d'organiser les objets en groupes (clusters) dont les membres ont en commun diverses propriétés (intensité, couleur, texture, etc). On peut regrouper les méthodes de segmentation en deux catégories : la segmentation non supervisée, qui vise à séparer automatiquement l'image en clusters naturels, c'est-à-dire sans aucune connaissance préalable des classes ; et la

segmentation supervisée, qui s'opère à partir de la connaissance de chacune des classes définies par une approche probabiliste.

Il existe beaucoup d'approches de segmentation : segmentation par seuillage, par région, par contour, par coopération région-contour et enfin par classification. Toutes ces approches visent à l'extraction des indices visuels de l'image. Le problème de segmentation est un problème très difficile. Étant donnée une image, il existe toujours plusieurs segmentations possibles ; Une bonne méthode sera donc celle qui permettra d'arriver à une bonne interprétation.

La segmentation est considérée comme un problème ouvert, non encore résolu. Il est classé parmi les problèmes dûs à sa complexité. Notre travail est consacré au méthode de segmentation par classification. le types d'algorithmes vont être utilisé : (Fuzzy c-means). Nous présenterons tout d'abord une description du fonctionnement de ce algorithme, ainsi qu'une comparaison de leur performance. Nous mettrons finalement en application par une série d'exemples testés.

Notre mémoire est structuré de la manière suivante :

Le **chapitre I** comprend en première partie une brève introduction aux concepts liés au domaine du traitement d'images. Les différentes définitions qui y sont développées sont celles des connaissances élémentaires de cette discipline.

Le **chapitre II** sera consacré à la segmentation des images en présentant les méthodes et les stratégies de segmentation d'image les plus connues, C'est une présentation générale à savoir celles de l'approche contour, de l'approche région et de l'approche coopérative. Et Un certain nombre de critère d'évaluation de qualité de résultat de segmentation ont été revus.

Dans le **Chapitre III**, nous abordons le cœur de notre travail qui est la classification FCM (Fuzzy C-Means).

Ce chapitre se compose de trois parties : dans la première nous allons présenter la logique floue, ensuite la méthode K-means dans la deuxième partie en fin la fusion des deux techniques. Dans le cadre de cette étude, on s'intéressera particulièrement à la méthode de classification floue "Fuzzy-C-Means", dont l'avantage majeur est la prise en considération des pixels mixtes qui ont des degrés d'appartenance à chaque classe.

Dans le **Chapitre IV** nous expliquons l'implémentation de méthode utilisé dans notre projet, en présentant les outils utilisés, ainsi que les résultats obtenus ; tout en discutant et critiquant ces résultats. Enfin, notre mémoire se clôturera par une conclusion générale présentant un aperçu rapide du travail réalisé et des enjeux rencontrés ainsi que des perspectives.

Chapitre 01

***Généralité sur le
traitement d'image***

1. Introduction

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

Dans ce chapitre nous présentons quelques notions de base du domaine de traitement d'images numériques tels que : la définition d'image, les types d'image, caractéristiques d'image, système de traitement d'image, analyse élémentaire, filtrage, La convolution, segmentation et en fin quelques exemples concrets de traitement d'images.

2. Définition d'une image :

L'image est une représentation d'une personne ou d'un objet par la peinture, le dessin, la photographie, le film, etc..... C'est aussi un ensemble structuré d'informations qui, après affichage sur l'écran, ont une signification pour l'œil humain.

Elle peut être décrite sous la forme d'une fonction $I(x, y)$ analogique continue, définie dans un domaine borné, tel que x et y sont les coordonnées spatiales d'un point de l'image et I est une fonction d'intensité lumineuse et de couleur. Sous cet aspect, l'image est inexploitable par la machine, ce qui nécessite sa numérisation. [5]

3. Image numérique :(numérisée) :

L'image numérique est l'image dont la surface est divisée en éléments de taille fixe appelés cellules ou pixels, ayant chacun comme caractéristique un niveau de gris ou de couleurs. [5]

La numérisation d'une image est la conversion de celle-ci de son état analogique en une image numérique représentée par une matrice bidimensionnelle de valeurs numériques $f(x, y)$, comme la montre la figure **I-1** où :

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

$f(x, y)$: niveau d'intensité.

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




Figure I-1: Représentation d'image numérique.

4. Caractéristiques d'une image numérique:

Comme nous l'avons vu, l'image est un ensemble structuré d'informations parmi ses caractéristiques nous pouvons citer les paramètres suivants:

4.1. Pixel :

Contraction de l'expression anglaise " Picture Elements ": éléments d'image, le pixel est le plus petit point de l'image, c'est une valeur numérique représentative des intensités lumineuses.

Si le bit est la plus petite unité d'information que peut traiter un ordinateur, le pixel est le plus petit élément que peuvent manipuler les matériels et logiciels sur l'image. La lettre A, par exemple, peut être affichée comme un groupe de pixels dans la figure ci-dessous. [3]




Figure I-2 :groupe de pixel formant la lettre A.

4.2. La résolution

La résolution d'une image correspond au niveau de détail qui va être représenté sur cette image. C'est le nombre de pixels par unité de longueur dans l'image à numériser. Elle est en dpi (dots par inch) ou en ppp (points par pouce).

Plus le nombre de pixels est élevé par unité de longueur de l'image à numériser, plus la quantité d'inflation qui décrit l'image est importante et plus la résolution est élevée. [4]

4.3. Dimension :

C'est la taille de l'image. Cette dernière se présente sous forme de matrice dont les éléments sont des valeurs numériques représentatives des intensités lumineuses (pixels). Le nombre de lignes de cette matrice multiplié par le nombre de colonnes nous donne le nombre total de pixels dans une image.[4]

4.4. La texture

Une texture est une région dans une image numérique qui a des caractéristiques homogènes. Ces caractéristiques sont par exemple un motif basique qui se répète .la texture est composée de Texel, l'équivalent des pixels.[6]

4.5. Bruit

Un bruit (parasite) dans une image est considéré comme un phénomène de brusque variation de l'intensité d'un pixel par rapport à ses voisins, il provient de l'éclairage des dispositifs optiques et électroniques du capteur.[2]



Figure I-3 : Image sans bruit .



Figure I-4 : Image avec bruit.

4.6. La luminance

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

Une bonne luminance se caractérise par :

- ✓ Des images lumineuses (brillantes);
- ✓ Un bon contraste : il faut éviter les images où la gamme de contraste tend vers le blanc ou le noir; ces images entraînent des pertes de détails dans les zones sombres ou lumineuses. L'absence de parasites. [1]

4.7. Contours et textures

Les contours représentent la frontière entre les objets de l'image, ou la limite entre deux pixels dont les niveaux de gris représentent une différence significative. Les textures décrivent la structure de ceux-ci. L'extraction de contour consiste à identifier dans l'image les points qui séparent deux textures différentes.[6]



Figure I-5: Contour d'une image.

4.8. Histogramme

L'histogramme des niveaux de gris ou des couleurs d'une image est une fonction qui donne la fréquence d'apparition de chaque niveau de gris (couleur) dans l'image. Pour diminuer l'erreur de quantification, pour comparer deux images obtenues sous des éclairages différents, ou encore pour mesurer certaines propriétés sur une image.

Il permet de donner un grand nombre d'information sur la distribution des niveaux de gris (couleur) et de voir entre quelles bornes est répartie la majorité des niveaux de gris (couleur) dans les cas d'une image trop claire ou d'une image trop foncée. [5]

La figure (I-6) montre une image avec son histogramme. [5]

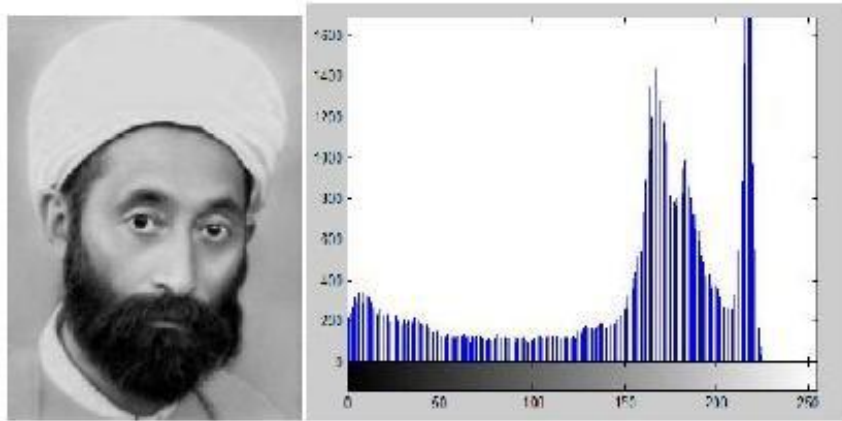


Figure I-6: Image avec histogramme

4.9. Le contraste

C'est l'opposition marquée entre deux régions d'une image, plus précisément entre les régions sombres et les régions claires de cette image. Le contraste est défini en fonction des luminances de deux zones d'images. [5]

Si L_1 et L_2 sont les degrés de luminosité respectivement de deux zones voisines A_1 et A_2 d'une image, le contraste C est défini par le rapport : [2]
$$C = \frac{L_1 - L_2}{L_1 + L_2}$$

5. Types d'images

On distingue trois types d'images :

- Binaire : 2 couleurs (arrière-plan et avant-plan).
- Monochrome : variations d'une même teinte.
- Polychrome : ' vraies ' couleurs. [5]

5.1. Images binaires (en noir et blanc)

Les images binaires sont les plus simples. Bichromies (dont les pixels ne peuvent avoir que les valeurs 0 et 1) .Le 0 correspond à un pixel noir et 1 à un pixel blanc. Le niveau de gris est donc codé sur un seul bit.



Figure I-7: Image binaire.

5.2. Images à niveaux de gris (Monochromes)

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

Le nombre de niveaux de gris dépend du nombre de bits utilisés pour décrire la " couleur " de chaque pixel de l'image. Plus ce nombre est important, plus les niveaux possibles sont nombreux.[5]



Figure I-8: Image Monochrome (256 couleurs).

5.3. Images en couleurs (Polychromes)

Elle est obtenue par la combinaison de trois couleurs dites primaires : rouge, vert et bleu (RVB). chaque couleur est codée comme une image à niveaux de gris, avec des valeurs allant de 0 à 255 .pour $R=V=B=0$ nous auront un noir pur, et pour $R=V=B=255$ nous auront un blanc pur. La représentation des images couleurs se fait donc soit par une image dont la valeur du pixel est une combinaison linéaire des valeurs des trois composantes couleurs, soit par trois images distinctes représentant chacune une composante couleur, on distingue généralement deux types d'images: [2]

- Images 24 bits ;
- Images à palettes ;



Figure I-9: Image polychrome (65536 couleurs).

6. Qualité de l'image numérique

Elle dépend, d'une part, de la qualité des images d'origine et, d'autre part, des moyens mis en œuvre pour convertir un signal analogique en signal numérique. Elle dépend aussi de :

- La qualité des périphériques de numérisation de l'image, du nombre de niveaux de gris ou de couleurs enregistrées, etc.
- La qualité de l'affichage à l'écran : définition de l'écran, nombre de teintes disponibles. [9]

Les critères d'appréciation de la qualité d'une image, tels que cités succinctement ci-dessus, dépendent largement de la structure même de l'image réaliste ou conceptuelle et de son mode de représentation (bitmap ou vectorielle). [5]

7. Images bitmap et images vectorielles

Les images appartiennent à deux grandes familles : bitmap (image-bit) et vectorielle. Alors qu'une image vectorielle est décrite à l'aide de courbes et d'équations mathématiques, une image bitmap est constituée de pixels et se réduit donc à une matrice de points. Si les

images vectorielles peuvent être manipulées avec beaucoup de facilité, les modifications de taille, par exemple, apportées à une image bitmap ne sont pas sans incidence. [5]

8. Système de traitement d'image

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

- Un système d'acquisition et de numérisation qui permet d'effectuer l'échantillonnage et la quantification d'une image.
- Une mémoire de masse pour stocker les images numérisées.
- Un système de visualisation.
- Une unité centrale permettant d'effectuer les différentes opérations de traitement d'images. [1]

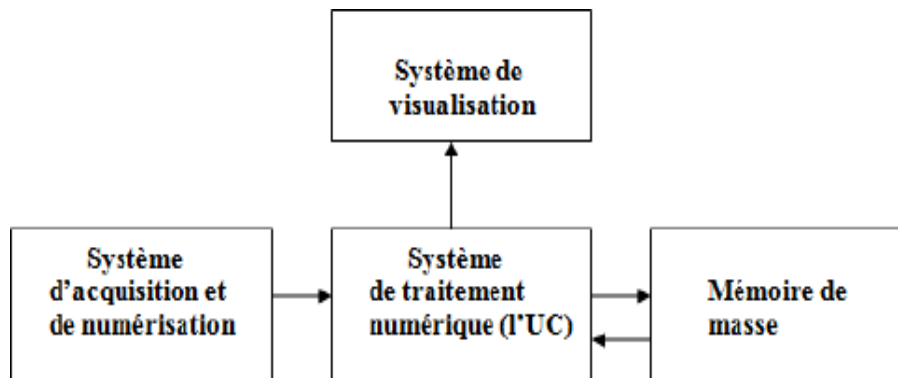


Figure I-10: Composition d'un système de traitement numérique.

8.1. Acquisition et numérisation :

L'acquisition d'images constitue un des maillons essentiels de toute chaîne de conception et de production d'images. Pour pouvoir manipuler une image sur un système informatique, il est avant tout nécessaire de lui faire subir une transformation qui la rendra lisible et manipulable par ce système. Le passage de cet objet externe (l'image d'origine) à sa représentation interne (dans l'unité de traitement) se fait grâce à une procédure de numérisation. Ces systèmes de saisie, dénommés optiques, peuvent être classés en deux catégories principales : les caméras numériques et les scanners. [5]

8.2. Visualisation

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

L'utilisation de différents types de reconstituteurs permet de transformer le signal numérique qu'est la matrice image en un signal analogique visible par l'œil de l'observateur.

Pour cela différents types de supports peuvent être employés : moniteur vidéo, clichés photographiques, impression sur papier. Dans tous les cas et pour chaque échantillon de l'image numérique, on recrée un nouvel élément d'image ou un nouveau pixel dont on choisit la forme de façon à reconstituer une image analogique qui soit la plus proche possible de l'image avant numérisation compte tenu des erreurs introduites lors de l'acquisition, de la numérisation et de la transmission .[9]

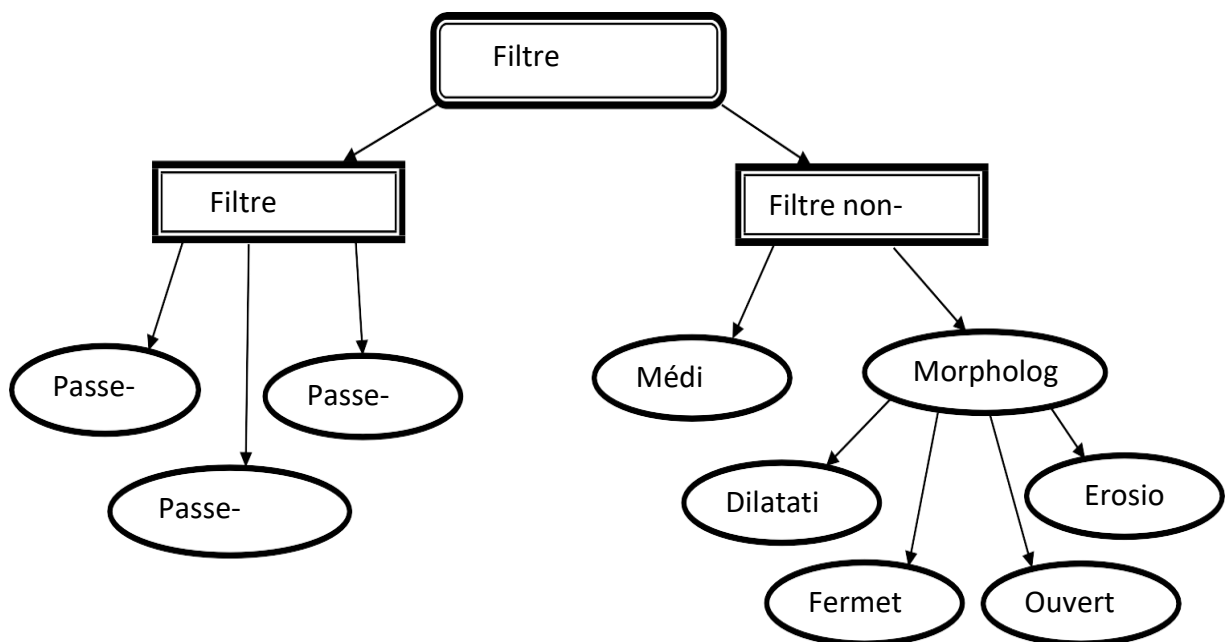
9. Traitement numérique des images

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

9.1. Filtrage numérique

Les images numériques telles qu'elles sont acquises, sont très souvent inexploitable pour le traitement d'images. Elles contiennent des signaux bruités. Pour remédier à cela, différents prétraitements pour l'amélioration ou la correction sont effectués. [5]

On peut scinder les filtres en deux grandes catégories :



9.1.1. Filtres linéaires

Les filtres linéaires transforment un ensemble de données d'entrée en un ensemble de données de sortie par une convolution bidimensionnelle qui est une opération mathématique. Ils permettent de supprimer le bruit dans l'image. Chaque filtre a une taille $N \times N$ avec N impair. [2]

Les filtres linéaires les plus connus sont les filtres passe-bas, passe-haut.

A. Filtre passe-bas (lissage) :

Ce filtre n'affecte pas les composantes de basse fréquence dans les données d'une image, mais doit atténuer les composantes de haute fréquence. L'opération de lissage est souvent utilisée pour atténuer le bruit et les irrégularités de l'image. Elle peut être répétée plusieurs fois, ce qui crée un effet de flou. En pratique, il faut choisir un compromis entre l'atténuation du bruit et la conservation des détails et contours significatifs. [1]

1	1	1
1	1	1
1	1	1

Figure I-11: Masque du filtre

B. Filtre Passe-haut (Accentuation) :

Le renforcement des contours et leur extraction s'obtiennent dans le domaine fréquentiel par l'application d'un filtre passe-haut. Le filtre digital passe-haut a les caractéristiques inverses du filtre passe-bas. Ce filtre n'affecte pas les composantes de haute fréquence d'un signal, mais doit atténuer les composantes de basse fréquence. [1]

$$H =$$

-1	-1	-1
-1	9	-1
-1	-1	-1

Figure I-12: Masque de filtre

9.1.2. Filtres non linéaire

Ils sont conçus pour régler les problèmes des filtres linéaires, Leur principe est le même que celui des filtres linéaires, il s'agit toujours de remplacer la valeur de chaque pixel par la valeur d'une fonction calculée dans son voisinage. La différence majeure, est que cette fonction n'est plus linéaire mais une fonction quelconque (elle peut inclure des opérateurs de comparaisons ou de classification). Les filtres non linéaires les plus connus sont : [1]

A. Filtre médian

Ce filtre est très utilisé pour éliminer le bruit sur une image qui peut être de différentes origines (poussières, petits nuages, baisse momentanée de l'intensité électrique sur les capteurs, ...). L'avantage de ce filtre réside dans le fait qu'il conserve les contours alors que les autres types de filtres ont tendance à les adoucir. [1]

L'algorithme de filtre médian est le suivant :

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



Figure I-13: Principe du filtre médian

B. Filtre maximum

On applique le même traitement que celui du filtre médian mais la valeur du pixel du centre comme la montre la figure I.14, va être changée par le maximum. [1]




Figure I-14: Principe du filtre maximum

C. Filtre minimum

On applique le même traitement que celui du filtre maximum mais, cette fois, la valeur du pixel du centre comme la montre la figure va être remplacée par le minimum. [1]




Figure I-15: Principe du filtre minimum.

9.2. Domaines d'application

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

De nouvelles applications pratiques sont possibles aujourd'hui et touchent tous les domaines d'activités, tels que : métiers du spectacle, de la radio, créations artistiques,... [9]

10. Conclusion

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

Nous pouvons, à présent, aborder au prochain chapitre les techniques de la segmentation d'image.

Chapitre 02

***Les approches de la
segmentation d'images***

1. Introduction :

Le processus d'analyse d'image être défini comme l'ensemble des méthodes et outil permettant de décrire complètement le contenu d'une image.

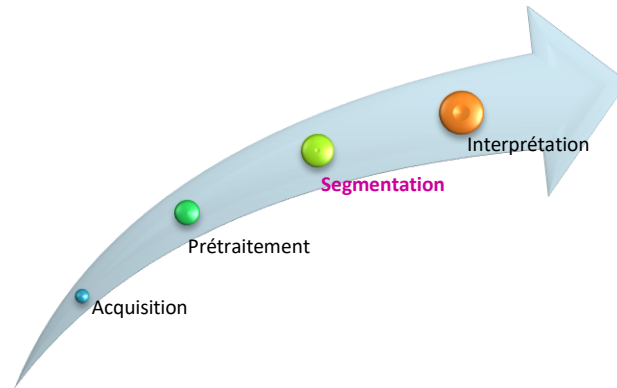


Figure II.1 : Analyse de l'image.

La segmentation d'image est avant tout un processus naturel, effectué en continu par notre cerveau sur l'ensemble de nos perceptions visuelles. En ce moment même, vous êtes en mesure de lire ce manuscrit de thèse parce que votre cerveau reçoit l'information visuelle présente sur cette page, l'analyse puis l'interprète. Avant de pouvoir comprendre ce texte, votre cerveau a isolé chaque mot de la page puis lui a donné un sens. De même, si vous regardez autour de vous (mais n'hésitez pas à reprendre la lecture ensuite), vous pourrez nommer chaque élément que vous voyez, parce que vous êtes en mesure de le dissocier de la scène globale et des autres éléments [7].

La segmentation d'image est une étape très importante et critique d'analyse d'image, donc une bonne segmentation d'image donnée une bonne analyse d'image car c'est à partir de l'image segmentée que les mesures sont effectuées pour l'extraction des paramètres discriminants en vue de la classification ou de l'interprétation. L'objectif de la segmentation est d'établir une description compacte et représentative de son contenu informationnel, plus exploitable que l'ensemble de ses points. Il s'agit de procéder à l'extraction d'indices visuels (primitives) pertinents, suffisamment corrélés avec les entités qui composent la scène d'où l'image est prise. La diversité des travaux menés dans le but de la compréhension de la vision humaine montre la complexité de la notion d'indice visuel et qu'il est bien difficile d'en donner une définition précise. Un indice visuel peut être défini comme une information perceptible directement à partir de la visualisation de l'image (contours, régions).

2. Segmentation d'image :

2.1. Définition de la segmentation :

La segmentation est une des étapes critiques de l'analyse d'images qui conditionne la qualité des mesures effectuées ultérieurement. C'est généralement une première étape d'un traitement plus complexe comme la reconnaissance de formes. Elle permet de cerner les formes des objets sur lesquels doit porter l'analyse. de délimiter des régions (l'intérêt et de les extraire du fond. Une bonne méthode de segmentation sera celle qui permettra d'arriver à une bonne interprétation. Elle devra donc avoir simplifié l'image sans pour autant en avoir trop réduit le contenu.




Figure II-2: Exemple de segmentation d'image.

À ce jour, il existe (les nombreuses méthodes de segmentation qui sont pratiquement toutes sensibles au bruit. il est donc nécessaire (le commencer par nettoyer l'image en appliquant les filtres usuels d'atténuation le bruit. Parmi les approches (le segmentation les plus connues), on peut citer : la segmentation basée sur le seuillage. le segmentation basée sur les régions. et la segmentation basée sur les contours. [9]

2.2. Définition formelle de la segmentation

Formellement, la segmentation d'une image A en régions R_i , $i = 1..n$, est définie par les propriétés suivantes : [13]

1. $U_{i=1}^n R_i = I$
2. $R_i \cap R_j = \emptyset; \forall i, j$ telle que $i \neq j$
3. $(R_i) = \text{vrai}; \forall i \in \{1, 2, \dots, n\}$
4. $(R_i \cap R_j) = \text{faux}; \forall i, j$ telle que $i \neq j$
5. R_i est un composant connexe; $\forall i \in \{1, 2, \dots, n\}$
 - P est un prédicat d'homogénéité.
 - La première condition indique que l'union des régions nous ramène à l'image de départ.
 - La deuxième indique que deux régions différentes sont disjointes.
 - La troisième exprime que les pixels appartenant à une région doivent satisfaire le critère d'homogénéité.
 - La quatrième exprime le critère d'homogénéité pour la segmentation en régions disjointes

2.3. Le choix d'une technique de segmentation:

Le choix est lié à :

- La nature de l'image (éclairage, contours, texture, etc).
- Aux opérations en aval de la segmentation (compression, reconnaissance des formes, Mesures, etc).
- Aux primitives à extraire (droites, régions, textures, etc).
- Aux contraintes d'exploitation (temps réel, espace mémoire, etc). [8]

2.4. Objectifs de la segmentation :

- Fournir des régions homogènes (selon un critère donné).
- Localiser de manière précise les contours des régions.
- L'étude et l'interprétation des structures anatomiques.
- Réduction de bruit. [8]

3. Les stratégies de segmentation :

En traitement d'image, il existe quatre types différents stratégies de la segmentation des images couleur, à savoir les stratégies scalaires, marginales, vectorielles et hybrides. [10]

3.1. Les stratégies scalaires :

L'approche scalaire commence par une fusion des n composantes de l'image multi composante. L'image sous forme mono-composante ainsi obtenue est traitée par la suite (**figure 1.2**). Par exemple, une image vectorielle couleur codée dans l'espace RVB peut être transformée, avant traitement, en une image scalaire. Cela peut être réalisé au moyen d'une analyse en composantes principales dont on ne retient que la première composante.

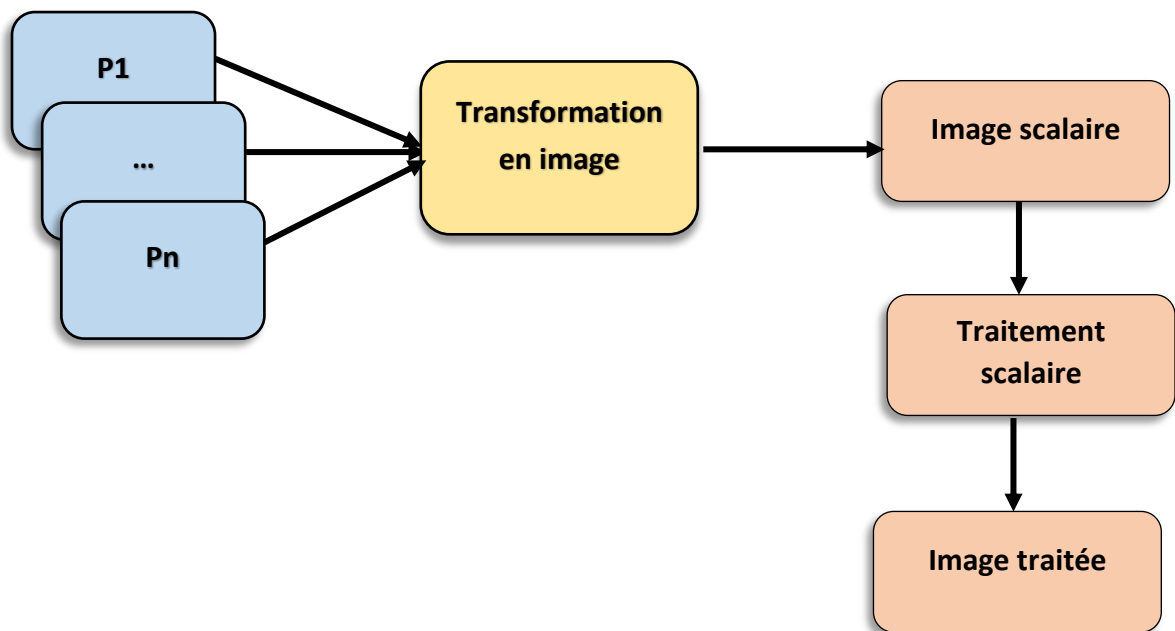


Figure II.3: Stratégie scalaire

3.2. Les stratégies marginales :

L'approche marginale opère un traitement scalaire sur chaque composante de l'image. Les résultats obtenus sont ensuite fusionnés en une seule image mono-composante (**Figure II.3**). Cette stratégie demande autant de traitements qu'il y a de composantes. [11]

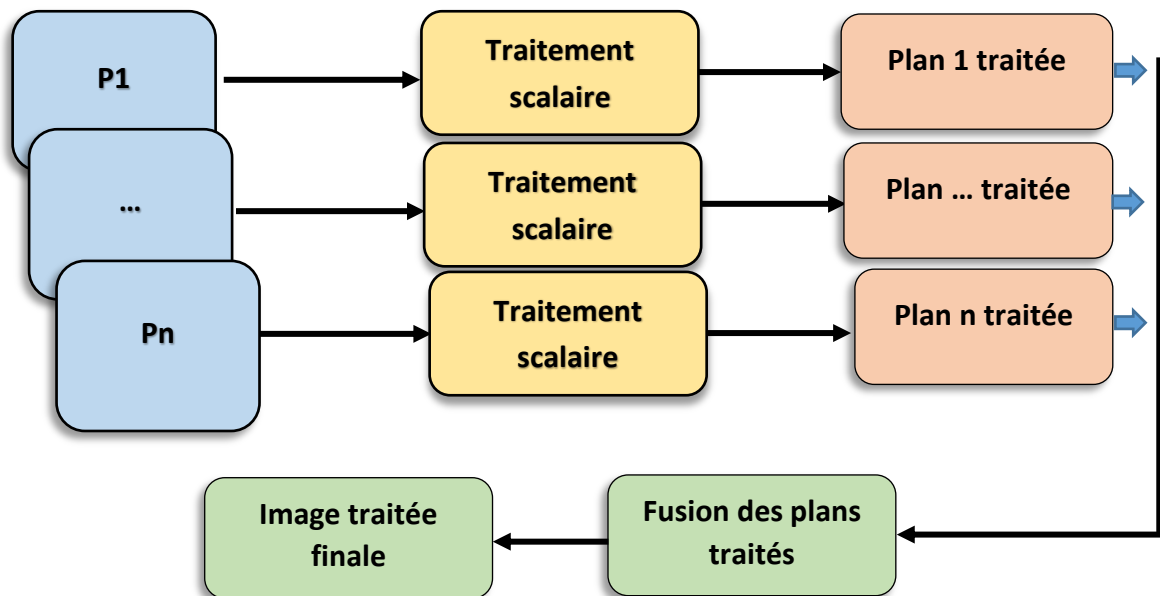


Figure II.4 : Les stratégies marginales

3.3. Les stratégies vectorielles :

L'approche vectorielle utilise directement, et de façon globale, l'information vectorielle présente dans l'image (**figure II.4**). La corrélation entre composantes est ainsi prise en compte. [11]




Figure II.5 : Les stratégies vectorielles

3.4. Les Stratégie hybride :

Le mélange des deux stratégies marginales et vectorielles résulte la stratégie hybride . Elle est couramment utilisée dans la segmentation par analyse d'histogrammes des images couleur.[11]

4. Les méthodes de segmentation :

4.1.Approche Contour :

Un contour est un ensemble des points d'une image numérique qui correspond à un Changement brutal de l'intensité lumineuse. [12]

Dans l'approche " **contour** ", on considère que les primitives à extraire sont les lignes de contrastes séparant des régions de niveaux de gris différents et relativement homogènes, ou bien des régions de texture différentes. En pratique, il s'agit de reconnaître les zones de transition et de localiser au mieux la frontière entre les régions. Il existe plusieurs méthodes de segmentation par contour qu'on peut regrouper en trois catégories : les méthodes dérivatives, les méthodes Analytiques et les méthodes déformables. [12]

4.1.1. Le processus « classique » de détection de contours :

Le processus classique de détecteur de contours suit les étapes suivantes: [12]



Figure II.6 : le processus classique de détecteur de contours.

- a) **La mise en évidence des contours** : C'est une étape important, elle permet de marquer les contours. Cette mise en évidence s'obtient par exemple par une différentiation (dérivation) de l'image.
- b) **La réduction des contours**: Elle agit de manière à ce que les contours mise en évidence ne fassent qu'un seul pixel d'épaisseur.
- c) **La binarisation des contours** : Elle permet d'obtenir une image contours binaire. La binarisation est une étape clef. Elle définit quels sont les contours que l'on considère comme importants et quels sont ceux que l'on rejette.
- d) **La description des contours** : Elle permet d'organiser les points de contours en structures simples tels les segments de droites, arcs de cercle, etc., et de détecter les contours fermés afin de les séparer.

Dans la littérature, il existe plusieurs méthodes utilisant l'approche contours, dans ce qui suit, nous allons présenter les plus importantes.

4.1.2. Les méthodes d'approche Contour :

4.1.2.1. Méthodes dérivatives :

Les méthodes dérivatives sont les plus utilisées pour détecter des transitions d'intensité par différenciation numérique (Première et deuxième dérivé). A chaque position, un opérateur est appliqué afin de détecter les transitions significatives au niveau de l'attribut de discontinuité choisi. Le résultat est une image binaire constituée de points de contours et de points non- contours. [2]




Figure II-7: Contour et ses dérivées.

De nombreuses techniques d'extraction de contours existent dans la littérature. Elles peuvent être classées comme suit : [13]

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

A. L'approche Gradient

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

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

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

Le module :

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

La direction (argument) :

$$\arg G(x, y) = \arctan \frac{G_y(x, y)}{G_x(x, y)} \quad \dots II.3$$

Il existe plusieurs opérateurs de gradient Parmi ses opérateurs, il y a les masques de Roberts, de Prewitt et de Sobel ...etc. [2]

Il existe plusieurs opérations permettant l'approximation du gradient, on peut citer :

	0°	45°	90°	135°
Robert	$\begin{pmatrix} 0 & 0 & 0 \\ 0 & 1 & 0 \\ 0 & 0 & -1 \end{pmatrix}$		$\begin{pmatrix} 0 & 0 & 0 \\ 0 & 0 & 1 \\ 0 & -1 & 0 \end{pmatrix}$	
Prewitt	$\begin{pmatrix} -1 & 1 & 1 \\ -1 & -2 & 1 \\ -1 & 1 & -1 \end{pmatrix}$	$\begin{pmatrix} -1 & -1 & 1 \\ -1 & -2 & 1 \\ 1 & 1 & 1 \end{pmatrix}$	$\begin{pmatrix} -1 & -1 & -1 \\ 1 & -2 & 1 \\ 1 & 1 & 1 \end{pmatrix}$	$\begin{pmatrix} 1 & 1 & 1 \\ -1 & -2 & 1 \\ -1 & -1 & 1 \end{pmatrix}$
Sobel	$\begin{pmatrix} -1 & 0 & 1 \\ -2 & 0 & 2 \\ -1 & 0 & 1 \end{pmatrix}$	$\begin{pmatrix} -2 & -1 & 0 \\ -1 & 0 & 0 \\ 0 & 1 & 2 \end{pmatrix}$	$\begin{pmatrix} -1 & -2 & -1 \\ 0 & 0 & 0 \\ 1 & 2 & 1 \end{pmatrix}$	$\begin{pmatrix} 0 & 1 & 2 \\ -1 & 0 & 1 \\ -2 & -1 & 0 \end{pmatrix}$
Kirsch	$\begin{pmatrix} -3 & -3 & 5 \\ -3 & 0 & 5 \\ -3 & -3 & 5 \end{pmatrix}$	$\begin{pmatrix} -3 & -3 & -3 \\ -3 & 0 & 5 \\ -3 & 5 & 5 \end{pmatrix}$	$\begin{pmatrix} -3 & -3 & -3 \\ 3 & 0 & -3 \\ 5 & 5 & 5 \end{pmatrix}$	$\begin{pmatrix} -3 & 5 & 5 \\ -3 & 0 & 5 \\ -3 & -3 & -3 \end{pmatrix}$

Tableau II .1: Principaux masques de calcul de gradient.

Cette approche permet une approximation des passages par zéro de la dérivée seconde de l'image qui détermine les transitions des intensités des pixels. [10]

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




Figure II-8: Détection de contour par les différents filtres.

B. L'approche du laplacien :

L'opérateur gradient de second ordre (Laplacien) peut être calculé par convolution d'un des deux masques M1, M2 qui utilisent respectivement 4 et 8 voisinages connectés. [8]

$$M1 = \begin{bmatrix} 0 & -1 & 0 \\ -1 & 4 & -1 \\ 0 & -1 & 0 \end{bmatrix}$$

$$M2 = \begin{bmatrix} -1 & -1 & -1 \\ -1 & 8 & -1 \\ -1 & -1 & -1 \end{bmatrix}$$

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



Figure II-9: Image originale (à gauche), contour détecté par le Laplacien.

4.1.2.2. Méthodes analytiques

A. Approche de Canny et Deriche

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

- **Une bonne détection** : faible probabilité d'oublier un vrai point de contour et une faible probabilité de marquer un point image comme contour alors qu'il ne l'est pas.
- **Une bonne localisation** : les points contours doivent être le plus près possible de leur position réelle dans l'image.
- **Une réponse unique** : à un contour unique : un point de contour ne doit être détecté qu'une seule fois par le filtre mis en œuvre.

Le détecteur de contour de Canny est le plus utilisé. Il est basé sur trois critères : la détection (robustesse au bruit), la localisation (précision de la localisation du point contour), l'unicité (une seule réponse par contour) [14]

Au filtre de Canny, Deriche a proposé un autre filtre (condition initiale différente) qui permet une simplification de son implémentation nous préférons souvent le détecteur de Deriche, qui répond exactement aux mêmes critères de qualité que celui de Canny .[16]

4.1.2.3. Méthodes déformables

Les modèles déformables, introduits par Kassont aussi connus sous les noms de « snakes » ou «contours actifs ».

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

En effet, celui-ci présente quelques inconvénients tels que la sensibilité à l'initialisation, au bruit, et le réglage difficile de ses différents paramètres. [15]

A. Contours actifs

Les contours actifs tirent leur origine des modèles élastiques, mais la communauté s'accorde à les attribuer à l'équipe Kass, Witkin et Terzopoulos, qui introduisirent les Snakes ou courbes minimisants. Les snakes tiennent leur nom de leur aptitude à se déformer comme des serpents. L'approche est variante, c'est à- dire que l'équation d'évolution du contour actif se déduit de la minimisation d'une énergie modélisant l'objet d'intérêt. Depuis la publication de cette équipe, les modèles déformables sont devenus un sujet très important pour la communauté du traitement d'images. [5]

B. Principe de fonctionnement des contours actifs

Un contour actif est une courbe définie dans l'image et qui est capable de se mouvoir sous l'influence de plusieurs forces qui vont la tirer ou la pousser vers la forme. Un snake consiste à placer aux alentours de l'objet à détecter une ligne initiale de contour, l'évolution se fait à travers un processus itératif qui déforme la courbe à chaque itération jusqu'à sa position finale

4.1.2.4. Les limites de segmentation par contour

Les principales limites des méthodes de détection de contour sont les suivantes [13] :

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

4.2.Approche région

La segmentation d'image par l'approche région consiste à découper l'image en régions. Les pixels adjacents sont regroupés en régions distinctes selon un critère d'homogénéité ou de similarité donnée. Ce critère peut être, par exemple, le niveau de gris, couleur, texture...etc.

Un processus de groupement est répété jusqu'à ce que tous les pixels dans l'image soient inclus dans des régions. Cette approche vise, donc, à segmenter l'image en se basant sur des propriétés intrinsèques des régions. [2]

Il existe plusieurs méthodes telles que la segmentation par croissance de région, par division de région, et par fusion de région que nous présentons ci-dessous.

4.2.1. Croissance de région (région growing) :

Cette technique consiste à faire progressivement accroître les régions autour de leur point de départ. L'initialisation de cette méthode consiste à considérer chaque pixel comme une région. On va essayer de les regrouper entre elles avec un double critère de similarité des niveaux de gris et d'adjacence. Le critère de similarité peut par exemple être : la variance des niveaux de gris de la région R est inférieure à un seuil.

Le principe de l'agrégation de pixel est le suivant : on choisit un germe (Le point de départ est le choix d'un ensemble de pixels appelés « germes ») et on fait croître ce germe tant que des pixels de son voisinage vérifient le test d'homogénéité. Lorsqu'il n'y a plus de pixels candidats dans le voisinage, on choisit un nouveau germe et on itère le processus. [5]




Figure II-10: Croissance progressive des régions

Parmi les avantages de cette technique, nous pouvons citer :

- La simplicité et la rapidité de la méthode.
- La segmentation d'objet à topologie complexe.
- La préservation de la forme de chaque région de l'image.

Cependant, il existe plusieurs inconvénients comme :

- L'influence du choix des germes initiaux et du critère d'homogénéité sur le résultat de la segmentation
- Une mauvaise sélection des germes ou un choix du critère de similarité mal adapté peuvent entraîner des phénomènes de sous-segmentation ou de sur-segmentation.
- Il peut y avoir des pixels qui ne peuvent pas être classés.

4.2.2. Segmentation par fusion de régions (Merge)

Les techniques de réunion (*region merging*) sont des méthodes ascendantes où tous les pixels sont visités. Pour chaque voisinage de pixel, un prédicat P est testé. S'il est vérifié les pixels correspondants sont regroupés dans une région. [13]

Les inconvénients de cette méthode se situent à deux niveaux :

- Cette méthode dépend du critère de fusion qui peut influencer sur le résultat final de la segmentation.
- Elle peut introduire l'effet de sous-segmentation.

4.2.3. Segmentation par division de régions (Split)

La division consiste à partitionner l'image en régions homogènes selon un critère donné. Le principe de cette technique est de considérer l'image elle-même comme région initiale, qui par la suite est divisée en régions. Le processus de division est réitéré sur chaque nouvelle région (issue de la division) jusqu'à l'obtention de classes homogènes [13].




Figure II-11: Décompositions successives des blocs.

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

4.2.4. Segmentation par division-fusion (Split and Merge)

Ces méthodes combinent les deux méthodes décrites précédemment, la division de l'image en de petites régions homogènes, puis la fusion des régions connexes et similaires au sens d'un prédicat de regroupement. On part du principe que chaque pixel représente à lui seul une région. Deux régions seront fusionnées si elles répondent aux critères de similarité des niveaux de gris et d'adjacence de régions. On s'arrête quand le critère de fusion n'est plus vérifié. [2]




Figure II-12 Agrégation itérative des blocs similaires au bloc 1.

Les inconvénients de cette méthode se situent à trois niveaux :


- Les régions obtenues ne correspondent pas, dans tous les cas, aux objets représentés dans l'image.
- Les limites des régions obtenues sont habituellement imprécises et ne coïncident pas exactement aux limites des objets de l'image.
- La difficulté d'identifier les critères pour agréger les pixels ou pour fusionner et diviser les régions. [2]

4.3. Segmentation par seuillage

4.3.1. Définition du seuillage


Le seuillage (thresholding en Anglais) représente un outil largement utilisé dans la segmentation d'image pour extraire des objets de leurs fonds en fonction d'un seuil. Tout problème de seuillage consiste alors à rechercher la valeur du seuil. La plupart des méthodes de seuillage déterminent le seuil en optimisant une fonction objective.

On distingue le Seuillage de base (simple) (2 classes) où le résultat du seuillage est une image binaire (Figure 2.19), et le multi-seuillage (multi-level thresholding en Anglais) qui est utile quand on a affaire à des images qui contiennent plusieurs objets ayant des luminances différentes. Pour extraire ces objets, plusieurs seuils sont nécessaires. Le résultat du seuillage est une image avec $n+1$ classes pour n seuils (Figure 2.20). [5]



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

Figure II-13: Seuillage simple d'un histogramme.



$$g(x, y) = \begin{cases} 2 & \text{si } f(x, y) \geq T_2 \\ 1 & \text{si } T_1 \leq f(x, y) < T_2 \\ 0 & \text{si } f(x, y) < T_1 \end{cases}$$

Figure II-14: Seuillage multiple d'un histogramme.

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

Les méthodes de seuillage peut être: Seuillage globale et seuillage local, manuelle.

4.3.2. seuillage globale

Seuillage globale : un seuil pour toute l'image, elle consiste à comparer le niveau de gris de chaque pixel x_i de l'image avec un seuil global fixe T (par exemple 127). On note b_i la nouvelle valeur du pixel, le seuillage est donné par l'expression suivante : [5]

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

4.3.3. seuillage locale

Seuillage local ou adaptatif : un seuil pour une portion de l'image. Les méthodes de seuillage locale prennent en considération la valeur des pixels voisins pour le calcul des seuils. [5]

5. Les critères d'évaluation :

Le problème de l'évaluation est crucial car il permet au chercheur de :

- Comparer une méthode de segmentation par rapport aux autres.
- Choisir l'algorithme le plus adéquate son application et de régler ses paramètres.

En fonction du problème à résoudre car le paramétrage des algorithmes est un problème bien connu aux chercheurs. Pour comparer de façon objective des méthodes de segmentation, il est préférable d'utiliser des images de synthèses dont les contours et les régions sont parfaitement localisées, l'inconvénient majeur de telles images est qu'ils ne reproduisent pas toutes les situations possibles et ils ne tiennent pas suffisamment compte de la réalité.

Les méthodes de mesure de la qualité de la segmentation qui existent actuellement peuvent être regroupées en trois grandes catégories :

- Les techniques d'évaluation par un expert humain (visuelles)
- Les techniques d'évaluation avec référence où l'on fait appel à des images de synthèses construites à la main par un expert du domaine d'application. Les techniques d'évaluation sans référence, dans le cas où l'on ne dispose pas de la vérité terrain et qu'il n'y a pas suffisamment d'informations a priori sur l'image. [11]

5.1. Evaluation de segmentation en contour :

La plupart des algorithmes d'analyse d'images s'intéressant à la détection des contours. un certain nombre d'algorithmes d'évaluation ont été fait dans ce sens, nous allons présenter dans cette partie une étude comparative de plusieurs critères d'évaluation de la segmentation.

A. Mesure de Abdou et Pratt :

C'est une méthode analytique qui tient compte de connaissances a priori sur l'image. Abdou et Pratt analysent la performance des détecteurs de contours avec un taux de probabilité de détection. [11]

B. Mesure de Pelli et Mallah :

Ces chercheurs ont proposés deux méthodes: [11]

1. Moyenne du carré des distances des points contours par rapport au contour idéal.

$$\text{Moy } d^2 = \frac{I_I}{I_A} \sum d^2(s) \dots \text{II.1}$$

I_I et I_A sont les nombre de points contours respectivement sur la carte de référence et la cartes des contours.

2. La Moyenne de la valeur absolue des distances des points contours détectés par rapport au contour idéal.

$$\text{Moy } d = \frac{I_I}{I_A} \sum |d(s)| \dots \text{II.2}$$

C. Critères de Fram et Deutsch :

Frame et Deutsch proposent deux critères P1 et P2 qui servent à évaluer l'extraction d'un seul contour dont on connaît la position exacte. [11]

- Les calculs se font sur la zone de contour notée Z.
- Un contour est optimal, s'il a un pixel d'épaisseur.

Soit N_1 le nombre de lignes de Z.

- N_i le nombre de pixels de contour de Z détectés dans l'image résultat (un seul est correct par ligne).
- N_e Le nombre de pixels détecté, dehors de Z. N_b le nombre de fausses détections dans Z (cas de 2 pixels par ligne). N_2 le nombre de lignes avec deux pixels dans Z.

$$P = \frac{N_i}{N_i + N_b + N_e} \dots \text{II.3}$$

Cet indice mesure la robustesse au bruit.

$$P = \frac{N_i}{N_i - N_2} \dots \text{II.4}$$

Cet indice vaut 1 s'il n'y a pas de lacune dans Z.

D. Critères de Baker :

Baker présenté des critères d'évaluation du détecteur de contour qui ne nécessitent pas la vérité de terrain, ces critères sont basés sur la contrainte des bords dans la scène. Les contraintes de bords sont tous : [11]

1. Les bords sont colinéaires.
2. Les bords se coupent en un point unique,
3. Les bords sont parallèles dans la scène,
4. Les bords se trouvent sur une ellipse.

5.2. Evaluation de segmentation en région :

Les algorithmes d'évaluation de la segmentation en région sont basés soit sur des calculs de distances entre pixels mal segmentés et les régions auxquelles ils appartiennent, soit sur les couples de régions ayant un recouvrement maximal

5.2.1. Evaluation non-supervisée :

L'évaluation non-supervisée des résultats de segmentation, consiste exécuter des mesures d'homogénéité des régions ou de contrastes entre régions, Stella et Shi dans [17], ont classifiés ces critères en deux grandes catégories : Les critères de Contraste et les critères d'adéquation au modèle. Les premiers s'intéressent à la variabilité inter-régions, alors que les seconds s'intéressent à l'uniformité en intensité ou en couleur à l'intérieur des régions.

5.2.2. Évaluation supervisée :

L'évaluation supervisée consiste à comparer le résultat fourni par un algorithme avec une segmentation de référence (vérité-terrain). Cette dernière peut être une image de synthèse ou une image construite à la main par un expert du domaine de l'application dans le cas d'images naturelles, en traçant des contours (par des médecins, des géographes, etc.), en utilisant des outils informatiques de dessin.

6. Conclusion :

Dans ce chapitre, nous avons présenté la segmentation d'image en se concentrant sur les méthodes et les stratégies de segmentation d'image les plus connues, C'est une présentation générale à savoir celles de l'approche contour, de l'approche région et de l'approche coopérative. Et Un certain nombre de critère d'évaluation de qualité de résultat de segmentation ont été revus.

Chapitre 03

*La méthode de
classification*

"Fuzzy C-Means"

FCM

Partie 1 : la logique floue

1. Introduction

L'homme perçoit, raisonne, imagine et décide à partir de modèles ou de représentations. Sa pensée n'est pas binaire. L'idée de la logique floue est de «capturer» l'imprécision de la pensée humaine et l'exprimer avec des outils mathématiques appropriés. La théorie des ensembles flous s'occupe de la subjectivité et de l'incertitude ou de l'imprécision. Elle trouve ses origines dans un certain nombre de constatations :

- La connaissance que l'être humain a d'une situation quelconque est généralement imparfaite,
- elle peut être incertaine (il doute de sa validité), ou imprécise (il a du mal à l'exprimer clairement).
- L'être humain résout souvent des problèmes complexes à l'aide de données approximatives : la précision des données est souvent inutile.
- Plus la complexité d'un système augmente, moins il est possible de faire des affirmations précises sur son comportement. [1]

2. Historique

Les racines de la logique floue se trouvent dans le principe de l'incertitude de Heisenberg. Dans les années 20, les physiciens ont introduit la troisième valeur $\frac{1}{2}$ dans le système logique binaire bivalent $\{0, 1\}$.

Au début des années 30, le logicien polonais Jan Lukasiewicz a développé le système logique avec trois valeurs puis l'a étendu à tous les nombres rationnels entre 0 et 1. Il a défini la logique floue comme une logique qui utilise la fonction générale de vérité, laquelle associe à une affirmation un niveau de vérité qui peut prendre toutes les valeurs entre 0 (faux) et 1 (vrai), c'est à dire $T : \{\text{Affirmation}\} [0,1] \rightarrow$

Dans les années 30, Max Black a appliqué la logique floue aux ensembles d'éléments ou de symboles. Il a appelé imprécision l'incertitude de ces ensembles. Il a dessiné la première fonction d'appartenance (membership function) d'un ensemble flou. [32]

En 1965 Lotfi Zadeh, de l'université de Berkeley aux USA, a publié l'article « Fuzzy sets » dans lequel il a développé la théorie des ensembles flous et introduit le terme fuzzy dans la littérature technique. L'idée de Zadeh consiste à utiliser le modèle de l'esprit humain qui dispose d'une très forte capacité pour appréhender la complexité et pour manier des notations vagues et imprécises. Cette compétence est due à l'habileté des humains à manipuler des informations imprécises et incertaines.

Ainsi, Zadeh a initié le développement de la logique floue dont l'objectif principal est d'imiter les fonctionnalités de l'esprit humain. Il résume l'objectif de la logique floue par «The construction of smarter machines». Aussi, Dubois et Prade, qui sont parmi les pionniers de la logique floue, affirment-ils : «The main motivation of fuzzy set theory is apparently the desire to build up a formal, quantitative framework that captures the vagueness of human knowledge as it is expressed via natural language» [32].

Depuis, la logique floue s'est confirmée comme étant un outil adéquat pour le traitement des imprécisions et des incertitudes dans les systèmes intelligents. Au niveau industriel, les différentes applications de la logique floue ont bien montré son utilité dans beaucoup de domaines tels que la robotique, le contrôle des automatismes de processus et le diagnostic médical.

3. Théorie des sous-ensembles flous

3.1. Notion d'ensemble et de sous-ensemble flou

Un problème de vocabulaire se pose pour le mot flou qui signifie (vague, confus). Cela ne doit pas être interprété comme on va le voir par un « p'tet bien qu'oui, p'tet bien qu'non » ! En aucun cas il ne s'agit d'un manque d'information pour une décision à prendre, mais d'une représentation qui prend en compte l'incertitude que l'on a du modèle.

Une théorie des ensembles flous permet de définir toutes les opérations classiques (conjonction, disjonction,...etc.). Elle englobe la théorie des ensembles classiques.

Une des notions fondamentales dans les mathématiques est la notion d'ensemble, créée par le mathématicien Georg Cantor. Il a défini les ensembles comme des collections d'objets, appelés éléments, bien spécifiés et tous différents.

Dans la théorie des ensembles, un élément appartient ou n'appartient pas à un ensemble. Ainsi, on peut définir un ensemble par une fonction caractéristique pour tous les éléments x de l'univers de discours U . L'univers de discours est l'ensemble référentiel qui contient tous les éléments qui sont en relation avec le contexte donné.

La fonction caractéristique de l'ensemble E , $\mu_E : U \rightarrow \{0,1\}$ est définie comme :

$$\mu_E(x) = \begin{cases} 1 & \text{si } x \in E \\ 0 & \text{si } x \notin E \end{cases}$$

Zadeh a étendu la notion d'un ensemble classique à l'ensemble flou qui le définit comme étant «une collection telle que l'appartenance d'un élément quelconque à cette collection peut prendre toutes les valeurs entre 0 et 1 ».

La théorie des ensembles flous repose sur la notion d'appartenance partielle : chaque élément appartient partiellement ou graduellement aux ensembles flous qui ont été définis. Les contours de chaque ensemble flou (cf. **Figure III.1**) ne sont pas « nets », mais « flous » ou

«graduels » [19]




Figure III.1 : Comparaison d'un ensemble classique et d'un ensemble flou.

3.2. Valeur d'appartenance

La valeur d'appartenance est le degré de compatibilité d'un élément avec le concept qui est représenté par un ensemble flou.

La fonction caractéristique de l'ensemble B $\mu_B(x): U \rightarrow [0,1]$ est appelée « fonction d'appartenance ». La valeur $\mu_B(x)$ mesure l'appartenance ou le degré avec lequel un élément x appartient à l'ensemble B : $\mu_B(x) = \text{Degré}(x \in B)$

3.3. Fonctions d'appartenance

Un ensemble flou est défini par sa « fonction d'appartenance », qui correspond à la notion de «fonction caractéristique » en logique classique. Supposons que nous voulions définir l'ensemble des personnes de « taille moyenne ». En logique classique, nous conviendrons par exemple que les personnes de taille moyenne sont celles dont la taille est comprise entre 1,60 m et 1,80 m. La fonction caractéristique de l'ensemble (cf. **Figure III.2**) donne « 0 » pour les tailles hors de l'intervalle [1,60 m ; 1,80 m] et « 1 » dans cet intervalle. [19]

L'ensemble flou des personnes de « taille moyenne » sera défini par une «fonction d'appartenance» qui diffère d'une fonction caractéristique par le fait qu'elle peut prendre n'importe quelle valeur dans l'intervalle [0, 1]. A chaque taille possible correspondra un «degré d'appartenance » à l'ensemble flou des « tailles moyennes » (cf. **Figure III.3**), compris entre 0 et 1.




Figure III.2 : fonction caractéristique.




Figure III.3 : fonction d'appartenance.

3.4. Opérations sur les ensembles flous

Les ensembles flous sont une généralisation des ensembles ordinaires. Ainsi trouve-t-on les mêmes opérateurs classiques, mais définis sur des notions floues :

3.4.1. Intersection

L'opérateur logique correspondant à l'intersection d'ensembles est le ET. Le degré de vérité de la proposition « A ET B » est le minimum des degrés de vérité de A et de B :

$$\mu(A \text{ et } B) = \text{Min}(\mu(A), \mu(B)) \dots \text{III.1}$$

Exemple

« Température Basse » est vraie à 0,7 « Pression Faible » est vraie à 0,5 « Température Basse ET Pression Faible » est donc vraie à 0,5 = MIN (0,7; 0,5)

Remarque : l'opérateur ET de la logique classique est bien respecté : 0 ET 1 donne bien 0.

3.4.2. Union

L'opérateur logique correspondant à l'union d'ensembles est le OU. Le degré de vérité de la proposition « A OU B » est le maximum des degrés de vérité de A et de B :

$$\mu(A \text{ OU } B) = \text{MAX}(\mu(A), \mu(B)) \dots \text{III.2}$$

Exemple

« Température Basse » est vraie à 0,7 « Pression Faible » est vraie à 0,5 « Température Basse OU Pression Faible » est donc vraie à 0,7.

Remarque : l'opérateur OU de la logique classique est bien respecté : 0 OU 1 donne bien 1.

3.4.3. Complément

L'opérateur logique correspondant au complément d'un ensemble est la négation.

$$\mu(\text{NON } A) = 1 - \mu(A) \dots \text{III.3}$$

Exemple

« Température Basse » est vraie à 0,7 « NON Température Basse », que l'on utilisera généralement sous la forme « Température NON Basse », est donc vraie à 0,3.

Remarque : l'opérateur négation de la logique classique est bien respecté : NON(0) donne bien 1 et NON(1) donne bien 0.

3.4.4. Égalité

Deux sous-ensembles flous A et B sont égaux si leurs fonctions d'appartenance sont en tous points égaux :

$$\mu(A) = \mu(B) \dots \text{III.4}$$

3.4.5. Inclusion

Un sous-ensemble flou A est inclus dans B (on note $A \subset B$) si tout élément de X qui appartient à A, appartient à B avec un degré au moins égal :

$$\mu_A(x) \leq \mu_B(x) \quad \forall x \in X \dots \text{III.5}$$

3.5. Distance entre deux sous-ensembles flous

Une distance entre deux sous-ensembles flous d'un même ensemble de référence est une évaluation de ce qui sépare ces deux sous-ensembles. Elle permet d'apprécier leur ressemblance ou leur dissemblance. Il existe plusieurs distances, mais les plus utilisées sont : la distance de Hamming et la distance euclidienne. [20]

Soient trois sous-ensembles flous A, B et C. Chaque mesure de distance doit satisfaire les conditions suivantes :

- Une distance n'est jamais une quantité négative : $D(A, B) \geq 0$
- La distance entre A et B est égale à la distance entre B et A
 $D(A, B) = D(B, A)$
- La distance entre A et A est toujours nulle
 $D(A, A) = 0$
- Si l'on associe à la distance une opération pour composer deux distances, on doit avoir la propriété suivante appelée inégalité triangulaire

$$D(A, C) \leq D(A, B) * D(B, C)$$

Où * est l'opération considérée, par exemple la somme pour la distance de Hamming.

3.5.1. Distance de Hamming

La définition générale de la distance de Hamming est la somme des valeurs absolues des différences entre les fonctions d'appartenance des objets correspondants :

$$D(A, B) = \sum_{i=1}^n |\mu_A(x_i) - \mu_B(x_i)| \dots \text{III. 6}$$

Où n est le nombre d'éléments dans l'ensemble de référence E .

Pour tenir compte du nombre d'éléments de l'ensemble de référence, on préfère utiliser la notion de «distance de Hamming relative » en divisant le résultat par le nombre d'éléments de référence, soit :

$$D(A, B) = \frac{1}{n} \sum_{i=1}^n |\mu_A(x_i) - \mu_B(x_i)| \dots \text{III. 7}$$

3.5.2. Distance Euclidienne

La distance euclidienne relative pour deux sous-ensembles flous A et B dans le même ensemble de référence E est définie de la manière suivante :

$$D(A, B) = \frac{1}{n} \sum_{i=1}^n (\mu_A(x_i) - \mu_B(x_i))^2 \dots \text{III. 8}$$

Où n est le nombre d'éléments dans l'ensemble de référence E .

4. Schéma d'une commande floue

La mise en œuvre d'une commande floue fait apparaître trois grands modules.

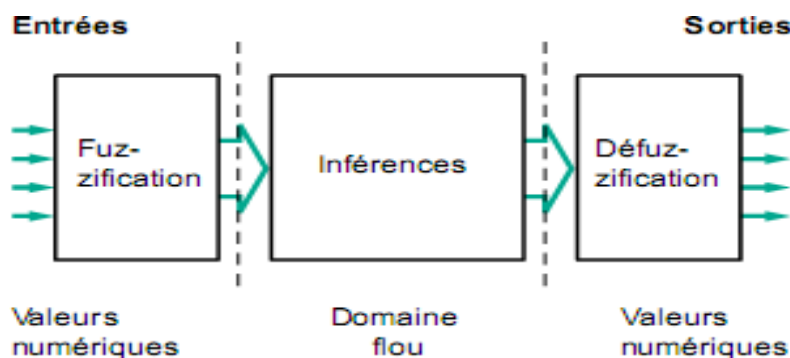


Figure III.4 : Représentation du schéma d'une commande floue.

4.1. Fuzzification

La fuzzification est l'opération qui permet de transformer une valeur numérique de l'entrée en une partie floue définie sur un espace de représentation lié à l'entrée [20].

Du choix de cet espace de représentation (numérique ou linguistique) dépend la nature de la partie floue E résultante de la fuzzification.

4.2. Défuzzification

La défuzzification est l'opération qui permet de transformer une partie floue de l'entrée en une valeur numérique définie sur un espace de représentation lié à l'entrée [20].

4.3. Mécanisme d'inférence

A partir des valeurs fuzzifiées, le mécanisme permet d'obtenir en utilisant les fonctions d'appartenance de chaque variable linguistique (entrées et sortie) ainsi que les règles floues, la fonction d'appartenance du sous ensemble flou solution de la commande.

En d'autres termes, il établit avec quel degré une commande satisfait la situation courante.

4.3.1. Proposition floue

Une proposition floue est un énoncé contenant un ou plusieurs prédicats flous selon qu'elle est simple ou composée. Sa valeur de vérité appartient à l'intervalle $[0,1]$ contrairement à la logique classique où la valeur de vérité d'une proposition est soit vraie (1) ou fausse (0). Les propositions floues sont à la base du raisonnement flou. Elles sont similaires à celles qu'on utilise dans notre vie quotidienne. En effet, elles sont exprimées en langage naturel. Ainsi, elles permettent au raisonnement flou d'être assez proche du raisonnement approximatif adopté par les humains. Des exemples de propositions floues sont:

- Il est obèse
- La température est élevée

Les propositions floues peuvent être combinées, comme dans le cas de la logique classique, par des connecteurs logiques tels que le 'et' et le 'ou'.

Une proposition floue composée est constituée de propositions floues simples reliées entre elles par des connecteurs logiques tels que 'et' et 'ou'. Par exemple, Il est jeune et il est obèse est une proposition qui contient deux propositions floues simples: Il est jeune et Il est obèse. Une autre manière de combiner des propositions floues simples consiste à utiliser l'implication. Une proposition floue utilisant l'implication est de la forme: Si x est A alors y est B. Par exemple, Si sa température est élevée alors il est malade. Une proposition floue du type Si...Alors est appelée une règle floue.

4.3.2. Règle floue

Une règle floue est une affirmation (Si...Alors) dont la prémisse et la conséquence sont des propositions floues ou des combinaisons de propositions floues par des connecteurs logiques (souvent le et 'et' le 'ou'). Chaque règle a deux parties :

- partie antécédente (prémisse ou condition), exprimée par Si....
- partie conséquente (conclusion), exprimée par alors...

La partie antécédente est la description de l'état de système. La partie conséquente exprime l'action à exécuter. La forme générale est :

Si (un ensemble de conditions est satisfait) alors (un ensemble de conséquences peut être exécuté).

Zadeh a été le premier à introduire la notion de règle floue sous la forme :

Règle : Si x est A, alors y est B.

Une règle floue (Si...Alors) est représentée par une implication floue ayant la même fonctionnalité que celle utilisée dans la logique classique. Par exemple, la règle floue:

Si x_1 est A_1 et x_2 est A_2 alors y est B où A_1 , A_2 , et B sont des ensembles flous représentés respectivement par les fonctions d'appartenances (x_1), (x_2) et (y)

5. Applications du flou

5.1. Logique floue et autres techniques

La logique floue est avant tout une extension, une généralisation de la logique booléenne. Elle permet d'introduire une gradualité dans des notions auparavant soit vraies soit fausses. Les probabilités, sans remettre en cause la nature binaire des événements (soit vrais soit faux), permettent de gérer l'incertitude de l'occurrence de ces événements. A la charnière entre ces deux approches, la théorie des possibilités (inventée par Lotfi Zadeh) permet de prendre en compte à la fois gradualité et incertitude (cf. *figure III.5*).

Les bases de règles floues sont souvent comparées pour les applications de commande / régulation aux réseaux neuronaux et à l'automatique classique. Ces trois approches nécessitent respectivement pour pouvoir être appliquées une expertise, des données servant à l'apprentissage, et un modèle dynamique du procédé. Leur comparaison n'est possible que quand les trois sont simultanément disponibles, ce qui est souvent le cas dans les études théoriques mais rarement en pratique ; si les trois sont disponibles, les aspects pratiques sont souvent prépondérants. En particulier, la logique floue peut être préférée pour son intelligibilité par les opérateurs [19].

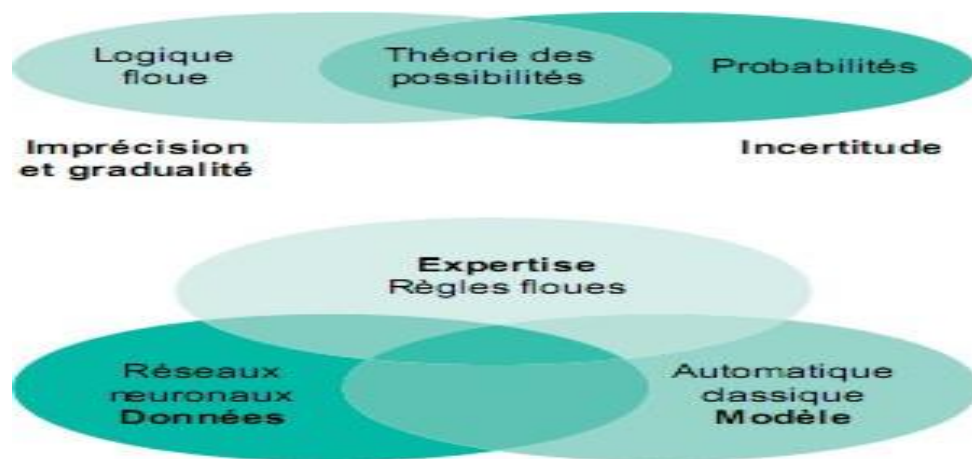


Figure III.5 : Comparaison de la logique floue et d'autres techniques.

Partie 2 : la méthode de classification k -means

1. Introduction

La classification automatique (ou clustering) est un domaine d'étude situé à l'intersection de deux thématiques de recherches majeures que sont l'analyse de données et l'apprentissage automatique. Ce domaine est en perpétuelle évolution du fait de l'apparition constante de nouveaux besoins portant à la fois sur la quantité ou la nature des données à traiter (numériques, symboliques, spatiales, histogrammes, etc.) que sur le type de classification attendue (partition, hiérarchie, schéma flou, etc.).

La segmentation par nuées dynamiques (ou k -means) est une méthode de classification automatique qui a pour objectif de partitionner l'espace en k classes, k connu.

A partir d'une partition initiale, on améliore itérativement la partition de l'espace en minimisant la variance et en maximisant l'écart entre les classes.

La méthode des k -means est un outil de classification classique qui permet de répartir un ensemble de données en classes homogènes. La plupart des images (photos, dessins vectoriels 2D, synthèses 3D...) vérifient localement des propriétés d'homogénéité notamment en termes d'intensité lumineuse. L'algorithme des k -means permet donc d'apporter une solution à la segmentation d'images.

2. Historique sur k -means

Le terme " k -means" a d'abord été utilisé par James MacQueen en 1967, Bien que l'idée remonte à Hugo Steinhaus en 1956. L'algorithme standard a été proposé par Stuart Lloyd en 1957 comme une technique d'impulsions Code Modulation, même si elle ne fut publiée qu'en 1982 [34].

3. Présentation de k -means

L'algorithme k -means, également appelé algorithme des nuées dynamiques, est l'algorithme de clustering le plus connu et le plus utilisé du fait de sa simplicité de mise en œuvre. Il partitionne les données d'une image en K clusters. L'algorithme renvoie une partition des données, dans laquelle les objets à l'intérieur de chaque cluster sont aussi proches que possible les uns des autres et aussi loin que possible des objets des autres clusters (cf. *figure III.6*). Le résultat est un ensemble de clusters compacts et séparés, si la valeur K du nombre du cluster est bien choisie au départ. [21].

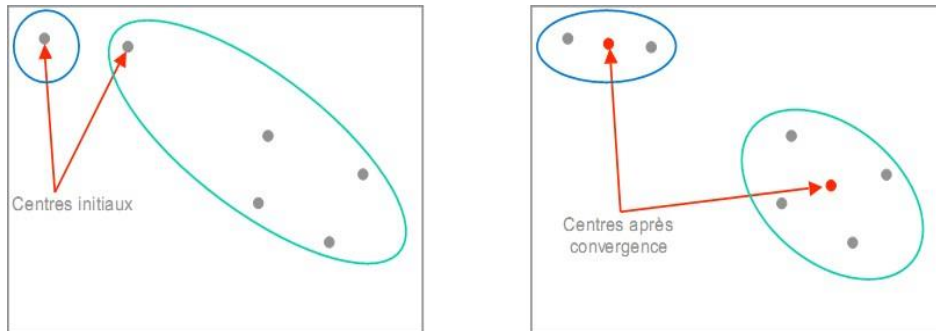


Figure III.6 : Principe de fonctionnement général de k -means.

4. k -means et la segmentation d'images

Les méthodes de classification (*clustering*) issues de l'analyse de données permettent de regrouper des objets possédant des propriétés similaires. Elles constituent donc approche naturelle pour réaliser une segmentation d'image.

La méthode des k -means a été très utilisée, d'une part pour sa simplicité de mise en œuvre et d'autre part car elle peut fournir une bonne approximation de la segmentation recherchée. Néanmoins cette méthode souffre d'un défaut qui a son importance en segmentation d'images : elle introduit des discontinuités spatiales assez fortes aux frontières des classes.

Des méthodes de régularisation sont donc généralement employées pour renforcer la connexité et ainsi réduire le nombre de composantes connexes de chaque classe.

5. Fonctionnement générale K-means




Figure III.7 : Démonstration des quatre étapes de k-means avec (K=3).

Les principales étapes de l'algorithme k-means sont : [23]

1. Choix aléatoire de la position initiale des K clusters.
2. (Ré-) Affecter les objets à un cluster suivant un critère de minimisation des distances (généralement selon une mesure de distance euclidienne).
3. Une fois tous les objets placés, recalculer les K centroïdes.
4. Réitérer les étapes 2 et 3 jusqu'à ce que plus qu'aucune réaffectation ne soit faite.

Cette méthode présente des inconvénients majeurs du fait que le nombre de clusters doit être choisi à l'initialisation. La classification finale est étroitement liée au nombre de classes initial.

6. Algorithme de k-means

On note $E(c)$ la fonction qui associe à un cluster c son centre de gravité défini par. $\frac{1}{\#c} \sum_{x \in c} x$

Début

// Initialisation

$\forall c \in C$

$m_c \leftarrow x / x \in D$ // Tirage uniforme dans la base de données

$c \leftarrow \{x \in D / \min_{q \in C} \|x - m_q\|^2 = \|x - m_c\|^2\}$

Fin \forall

Tant que $\exists c \in C / m_c \neq E(c)$

$\forall c \in C$

$m_c \leftarrow E(c)$

$c \leftarrow \emptyset$

Fin \forall

$\forall x \in D$

$\hat{C} \leftarrow \arg \min_{c \in C} \|x - m_c\|^2$

$\hat{C} \leftarrow \hat{C} \cup x$

Fin \forall

Fin tant que

Fin

7. Intérêt et Limitation de k -means

7.1. Intérêt de k -means

Cet algorithme est très populaire car extrêmement rapide en pratique. En effet, le nombre d'itérations est typiquement inférieur au nombre de points. En terme de performance, cet algorithme ne garantit pas un optimum global [22].

7.2. Limitation de k -means

L'utilisateur doit choisir le nombre k de classes et il n'y a pas de critère unique pour déterminer le meilleur nombre de classes ; Lorsque les classes ne sont pas bien séparées, les k -means tendent à trouver uniquement des classes "sphériques", de même effectif et de même volume. Plusieurs initialisations peuvent conduire à plusieurs partitions très différentes dans leur composition, mais très proches et quasi-optimales au sens du critère J_m .

8. Domaines d'applications

L'algorithme K -means clustering est couramment utilisé en vision par ordinateur comme une forme de segmentation d'image. Les résultats de la segmentation sont utilisés pour faciliter la détection des frontières et la reconnaissance d'objets. Dans ce contexte, la distance euclidienne standard est généralement insuffisante dans la formation des clusters. Au lieu de cela, une mesure de distance pondérée en utilisant les coordonnées des pixels, de couleur RGB pixel et / ou l'intensité et la texture de l'image est couramment utilisé.

9. Exemples sur k -means



Image originale

Résultat obtenu avec $K=2$ Résultat obtenu avec $K=3$

Figure III.8 : Image originale, application k -means avec $K=2$ et $K=3$.

Partie 3 : la méthode de classification "Fuzzy C-Means" ou FCM**1. Introduction**

La propriété d'ensembles flous qui est exploitée en traitement d'images, et plus précisément la classification où les classes, appelées aussi régions, sont représentées par des ensembles flous. Cela est fort utile lorsque les régions ne peuvent pas être définies de manière nette et précise. Leur manipulation en gardant le caractère flou permet de traiter des données imprécises, incertaines et/ou redondantes d'une manière plus flexible.

La classification floue autorise le chevauchement des régions. Une segmentation non floue peut être obtenue par affectation de chaque pixel à la classe pour laquelle son degré d'appartenance est maximal.

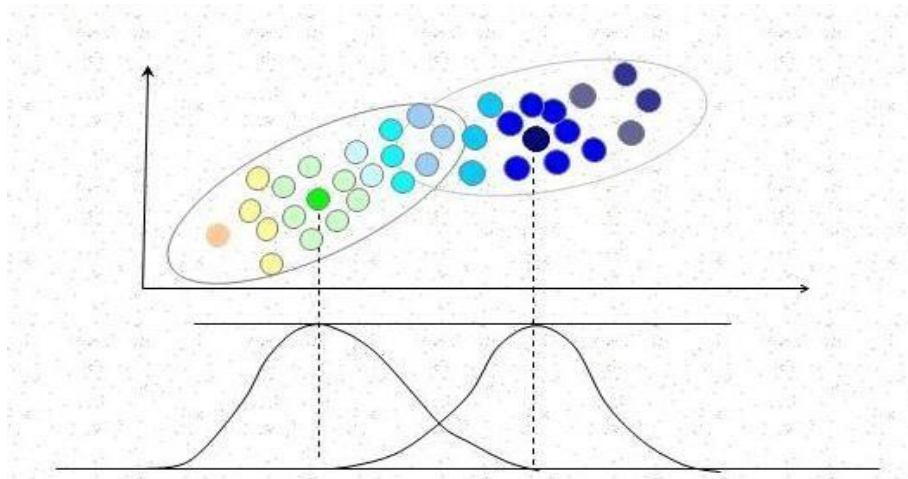


Figure III.9 : Exemple de classification (classes floues)

2. Historique

L'algorithme des c-moyennes floues généralise l'algorithme des k-moyennes [25], en permettant la classification floue basée sur la théorie des ensembles ou la notion d'ensemble flou a été introduite dans la définition des classes floues. Cet algorithme a été développé essentiellement par Bezdek qui s'y est intéressé [24], [26] et l'a développé, à partir des idées originales de Ruspini (clustering flou)[33] et de Dunn (ISODATA flou) [23].

On présente dans ce qui suit l'algorithme de classification (FCM) très populaire, basé sur la logique floue, connu pour son efficacité et sa robustesse.

3. Algorithme de classification floue

3.1. L'algorithme C-moyennes floues ("Fuzzy C-Means" ou FCM)

L'algorithme des C-moyennes floues [25], effectue une optimisation itérative en évaluant de façon approximative les minimums d'une fonction d'erreur. Il existe toute une famille de fonctions d'erreur associées à cet algorithme qui se distinguent par des valeurs différentes prises par un paramètre réglable, m , appelé indice de flou "fuzzy index" et qui détermine le degré de flou de la partition obtenue. Les FCM sont un cas particulier d'algorithmes basés sur la minimisation d'un critère ou d'une fonction objectif.

Dans ce cas, les x_j ne sont plus assignés à une unique classe, mais à plusieurs par l'intermédiaire de degrés d'appartenance u_{ij} du vecteur x_j à la classe i . Le but des algorithmes est alors non seulement de calculer les centres de classe B mais aussi l'ensemble des degrés d'appartenance des vecteurs aux classes.

3.2. Fonctionnement de l'algorithme FCM [21]

L'algorithme fuzzy c-means est un algorithme qui repose sur le même principe que le K-Means mais qui à recours à la logique des ensembles flous (utilisation de probabilités).

L'algorithme suivant montre les étapes de FCM

1. initialiser les centres
2. fixer le paramètre m (coefficient flou).
3. Calcul de la partition floue initiale U (la matrice d'appartenance)
4. Répéter :
 - calcul des nouveaux centres
 - calcul de la nouvelle partition floue
 Tant que le critère d'arrêt n'est pas vérifié.

3.3. Présentation de l'algorithme FCM

Si U_{ij} est le degré d'appartenance de x_j à la classe i , la matrice, $C \times N$, $U = [u_{ij}]$ est appelée matrice de C-partition floue si et seulement si elle satisfait:

$$(\forall i \in \{1 \dots C\})(\forall j \in \{1 \dots N\}) u_{ij} \in [0,1]$$

$$0 < \sum_{j=1}^N u_{ij} < N \dots III.9$$

$$\forall j \in \{1..N\} \sum_{i=1}^c u_{ij} = 1 \dots III.10$$

Bezdek a montré [25] que le problème de partition de X en C classe floues pouvait être

formulé comme la minimisation d'une fonctionnelle $J(B, U, X)$ définie par :

$$J(B, U, X) = \sum_{i=1}^c \sum_{j=1}^N u_{ij}^m d^2(x_j, b_i) \dots III.11$$

Sous les contraintes (III.9), (III.10) où :

- $m > 1$ est un paramètre contrôlant le degré de flou de la partition résultante
- $(x_j, b_i) \rightarrow d^2(x_j, b_i)$ est une distance du vecteur x_j au prototype b_i

Obtention de U et B

Si $d^2(x_j, b_i) \neq 0$

$$u_{ij} = \left[\sum_{k=1}^c \left(\frac{d^2(x_j, b_i)}{d^2(x_j, b_k)} \right)^{\frac{2}{m-1}} \right]^{-1} \dots III.12$$

Si $d^2(x_j, b_i) = 0$, x_j est un prototype b_i et $u_{ij} = 1$ avec $u_{ik} = 0$, $k \neq i$.

$$b_i = \frac{\sum_{k=1}^n u_{ik}^m x_k}{\sum_{k=1}^n u_{ik}^m} \dots III.13$$

L'algorithme des C-moyennes floues (FCM) consiste alors en l'application itérée de (III.12) et (III.13) jusqu'à stabilité des solutions. Le critère d'arrêt des itérations, définissant cette stabilité, peut par exemple consister en l'étude de la norme de la matrice U ou en la stabilité des centres de classe sur deux itérations successives.

3.4. Déroulement de FCM [28]

Étape 1: fixer les paramètres :

C : nombre de classes,

ε : seuil représentant l'erreur de convergence (par exemple $\varepsilon = 0.001$), m : degré de flou, généralement pris entre [1.5, 3],

Étape 2: Initialiser la matrice degrés d'appartenances U par des valeurs aléatoires dans l'intervalle [0,1].

Étape 3: mettre à jour le prototype B par la relation (III.13), Calculer $J(B, U, X)$ par (III.11).

Étape 4 : - Mettre à jour la matrice degrés d'appartenance par la relation (III.12),

- Calculer $J(B, U, X)$ par (III.11).

Étape 5 : Répéter les étapes 3 à 4 jusqu'à satisfaction du critère d'arrêt qui s'écrit :

$$|J'(B, U, X) - J(B, U, X)| < \varepsilon$$

4. Domaine d'application

L'algorithme FCM a été largement utilisé pour la segmentation des images de cerveau, quels que soient la modalité et le type d'acquisition (mono ou multi-spectrale). De nombreux travaux ont notamment été effectués en imagerie par résonance magnétique [29]. En IRM fonctionnelle, la méthode FCM est utilisée pour segmenter les régions activées (simulation et aires motrices) du cerveau.

Les pixels étant représentés par leur niveau de gris, les auteurs ont montré non seulement que l'algorithme avait des performances comparables à l'analyse de corrélation standard (avec l'avantage de ne nécessiter aucune connaissance a priori sur le paradigme), mais aussi que le FCM détectait des zones effectivement activées qui restaient silencieuses avec la corrélation [30].

5. L'algorithme FCM appliqué à la segmentation d'images

Un algorithme de segmentation par classification floue de pixels est constitué de deux étapes :

- La division de l'ensemble des pixels en un nombre donné de classes non-disjointes. Durant cette première partie, on cherche à conserver le plus longtemps possible les informations utiles, jusqu'au moment de la prise de décision (défuzzification).
- La définition des différentes régions contenues dans l'image, qui pourra s'effectuer par seuillage par rapport à un degré d'appartenance donné ou plus simplement en choisissant d'attribuer chaque pixel à la classe pour laquelle son degré d'appartenance est maximal.

Une autre manière, qui permet de reculer la prise de décision d'une étape supplémentaire, est d'opérer sur une partition floue de l'ensemble des pixels en deux classes non-disjointes : les contours et le reste de l'image.

Comme dans les techniques de segmentation par classification il n'est pas nécessaire de classer tous les pixels d'une image, mais de classer simplement les différentes valeurs de niveaux de gris que l'on trouve dans celle-ci, l'algorithme FCM peut être adapté au cas de la classification floue des N niveaux de gris d'une image [36].

6. Intérêt, limitations de FCM [26]

6.1. Avantages

Conserve la complexité des centres mobiles, tout en étant moins sensible au bruit grâce à la pondération par les degrés d'appartenance.

6.2. Limitations

La plupart des méthodes de classification utilisées, y compris le FCM, souffrent de trois défauts [27].

1. Moindre sensibilité au bruit
2. Le nombre de clusters doit être fourni à l'avance (**Algorithmes supervisés**),
3. Chaque région est caractérisée par un centre, et les degrés d'appartenance sont calculés en faisant intervenir la distance euclidienne d'où une forme nécessairement **hyper-sphérique**.

7. Exemple sur FCM



Image originale



Résultat obtenu avec K=2



Résultat obtenu avec K=3

Figure III.10 : Image originale, application FCM avec K=2 et K= 3.

Conclusion

Dans ce chapitre, nous avons présentées une définition de la logique floue, la théorie des ensembles flous, la valeur d'appartenance, ainsi que la fonction d'appartenance que l'on va introduire dans la troisième partie.

Nous avons présentées ici une méthode de classification non supervisée et qui est très souvent utilisée dans la segmentation des images d'une façon générale.

L'algorithme des K-Moyennes (KM) est l'une des méthodes les plus connues parmi les techniques de classification non supervisée.

Cet algorithme de classification est extrêmement rapide en pratique. En effet, le nombre d'itérations est typiquement inférieur au nombre de points.

L'algorithme de k-moyennes est capable de trouver des classes satisfaisantes là où il n'y a pas de relation entre les individus de l'échantillon. Ainsi on peut distinguer des sous-classes dans une même classe d'un échantillon.

Et nous avons présenté une méthode pour la classification non supervisée des images. L'algorithme des c-moyennes floues est proche de l'algorithme des k-moyennes mais présente l'avantage d'une sensibilité à l'initialisation plus faible. Où l'on introduit la notion d'ensemble flou dans la définition des classes. Cet algorithme utilise un critère de minimisation des distances intra-classes et de maximisation des distances inter-classes, mais en tenant compte des degrés d'appartenance et on optimisant la fonction J .

Chapitre 04

Tests et résultats

1. Introduction

La segmentation d'image, le partitionnement d'une image en régions homogènes en fonction d'un ensemble de caractéristiques, est un élément clé dans l'analyse d'images et de la vision par ordinateur. Le regroupement est l'une des méthodes disponibles à cet effet. Le regroupement est un procédé qui peut être utilisé pour classer les pixels en fonction de similitude selon la couleur ou le niveau de gris de l'intensité du pixel.

Le FCM a été utilisé pour une segmentation rapide et vif "dur". La théorie des ensembles flous a amélioré ce processus en permettant la notion d'appartenance partielle, dans laquelle un pixel de l'image peut appartenir à plusieurs groupes selon un degré d'appartenance. Ce regroupement «soft» permet un calcul plus précis des membres du cluster, et a été utilisé avec succès pour la classification de l'image et de la segmentation non supervisée d'images médicales, géologiques et satellite etc...

2. Système de travail

Pour réaliser aisément notre application, nous avons choisi de travailler sous Matlab R2013b. Matlab pour « MATtrix LABoratory », est un logiciel qui a été conçu pour fournir un environnement de calcul numérique de haut niveau. Il est particulièrement performant pour le calcul matriciel car sa structure de données interne est basée sur les matrices. Il dispose également de grandes capacités graphiques pour, par exemple, la visualisation d'objets mathématiques complexes. Son fonctionnement repose sur un langage de programmation interprété qui permet un développement très rapide. Pour des applications nécessitant un temps de calcul plus élevé, un langage compilé comme le C++ est mieux adapté.

L'interface Matlab se compose d'une fenêtre principale divisée en trois sous-fenêtres.

- En base à gauche, il y a une fenêtre contenant un onglet : Workspace, Le Workspace permet de gérer les variables utilisées.
- Ou milieu, il y a une grande fenêtre : Command Windows. La Command Window est la fenêtre d'interaction avec Matlab.
- En gauche ; il y a une fenêtre contenant un onglet : Current Folder qui contient la hiérarchie de dossiers de Matlab.

Pour la programmation, nous avons adopté Matlab pour les raisons suivantes :

- La syntaxe de Matlab, est simple et très parlante, elle est facile à assimiler.
- Matlab possède de nombreuses fonctions prédéfinies utiles en mathématiques que nous allons étudier au cours de ces travaux pratiques.
- Matlab facilite la manipulation des images médicale format DICOM.
- Matlab propose des commandes pour créer certaines matrices particulières très simplement.

- Toutes les fonctions et les opérations relatives aux matrices sont très optimisées et utiliser aussi souvent que possible.
- En plus des commandes, Matlab permet d'inclure dans des m-files des instructions de programmation classiques.

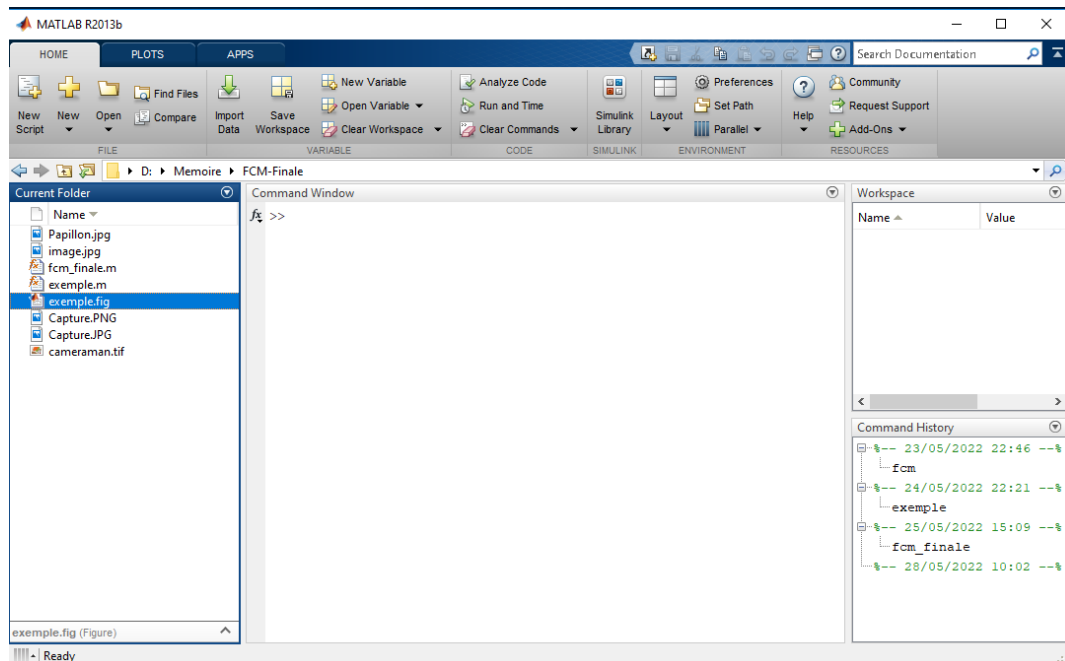


Figure IV. 1 : L'interface de MATLAB

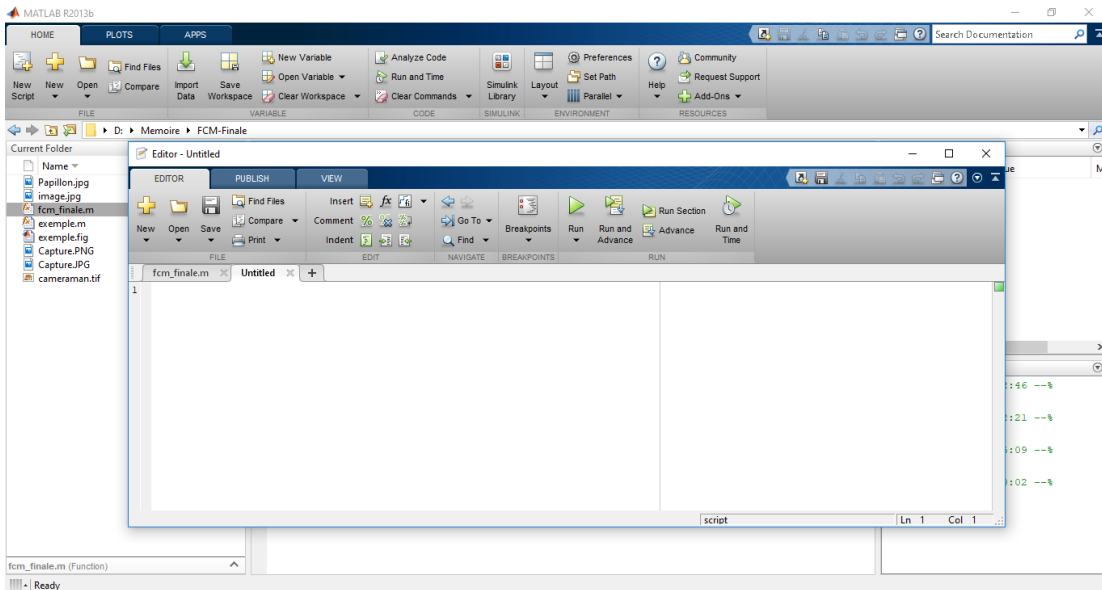


Figure IV. 2 : Le script de Matlab

3. Algorithme :

Les C-moyens flous (FCM) algorithme suit les mêmes principes que l'algorithme K-moyens en ce qu'elle compare la valeur de chaque pixel avec la valeur du centroïde. La principale différence est que, au lieu de prendre une décision difficile sur quel cluster pixel doit appartenir, il attribue une valeur comprise entre 0 et 1 décrivant «combien ce pixel appartient à ce cluster" pour chaque cluster. Règle floue indique que la somme de la valeur d'appartenance d'un pixel à tous les clusters doit être 1. Plus la valeur d'adhésion est grande plus il est probable que le pixel appartienne à ce cluster. Le regroupement FCM est obtenu en minimisant une fonction objective indiquée dans l'équation (IV.1) :

$$J = \sum_{i=1}^n \sum_{k=1}^c \mu_{ik}^m |p_i - v_k|^2 \dots IV.1$$

où:

J : est la fonction objective

n : est le nombre de pixels dans l'image E

c : est le centroïdes

μ : est la valeur d'appartenance floue de la table

m est un facteur de flou (une valeur > 1)

p_i est le pixel i dans E

v_k est le centreroide k^{eme} cluster

$|p_i - v_k|$ est la distance euclidienne entre p_i et v_k défini par l'équation (IV.2):

$$|p_i - v_k| = \sqrt{\sum_{i=1}^n (p_i - v_k)^2} \dots IV.2$$

Le calcul du centreroide de k^{eme} cluster est obtenu en utilisant l'équation (IV.3):

$$v_k = \frac{\sum_{i=1}^n \mu_{ik}^m p_i}{\sum_{i=1}^n \mu_{ik}^m} \dots IV.3$$

Le tableau d'appartenance floue est calculé en utilisant l'équation d'origine (4):

$$\mu_{ij} = \left[\sum_{k=1}^c \left(\frac{|p_i - v_j|}{|p_i - v_k|} \right)^{\frac{2}{m-1}} \right]^{-1} \dots IV.4$$

4. Pseudo-code :

Comme mentionné précédemment, il s'agit d'un processus itératif. Le pseudo-code est le suivant:

Étape 1: Définir le nombre de centroides, le paramètre flou (une constante > 1), et la condition d'arrêt

Étape 2: Initialisation de la matrice de partition floue **Étape 3:** Définir le compteur de boucle $k = 0$

Étape 4: Calculer les centroides, le calcul de la valeur objective J

Étape 5: Pour chaque pixel, pour chaque groupe, de calculer les valeurs d'appartenance dans la matrice

Étape 6: Si la valeur de J entre les itérations consécutives est inférieure à la condition d'arrêt, puis s'arrêter; sinon, réglez $k = k + 1$ et passez à l'étape 4

Étape 7: Défuzzification et segmentation

5. Présentation et implémentation du système de segmentation d'image

Nous avons présenté les différentes phases de système implémenté comme suite :

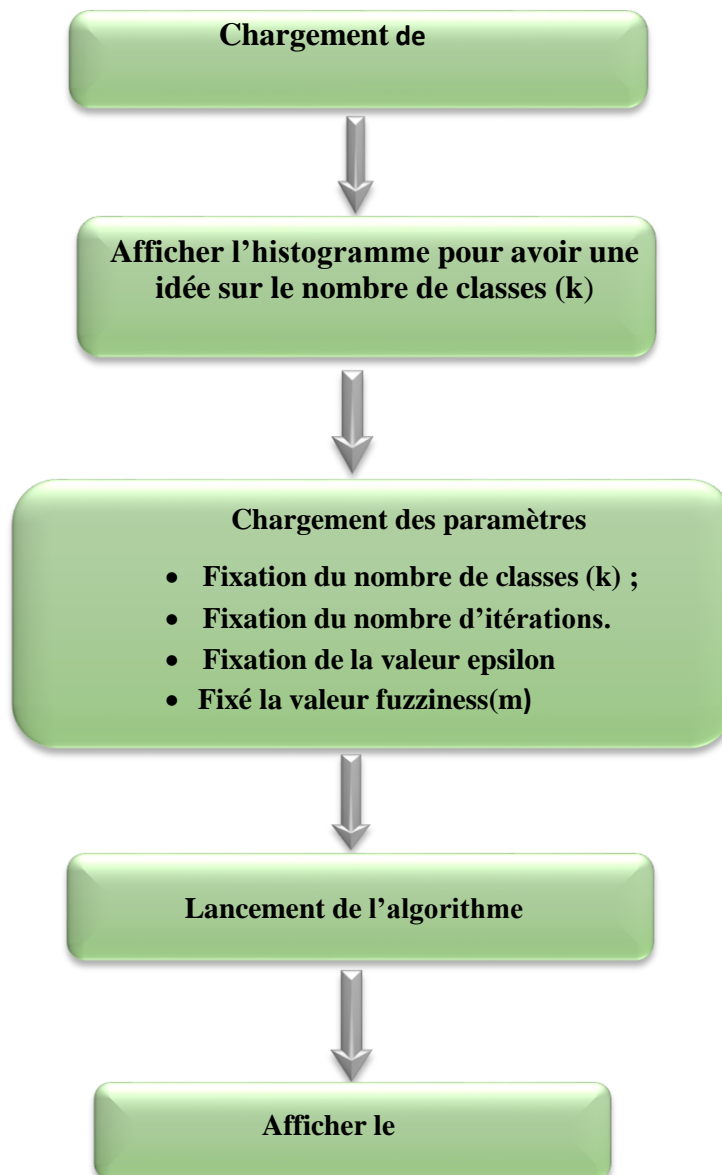


Figure IV. 3 : Schéma général de l'application.

6. Présentation de l'application

6.1. Interface principale

Notre logiciel effectue une segmentation sur les images satellitaires il est constitué d'un menu pour accéder à ces différentes fonctionnalités.

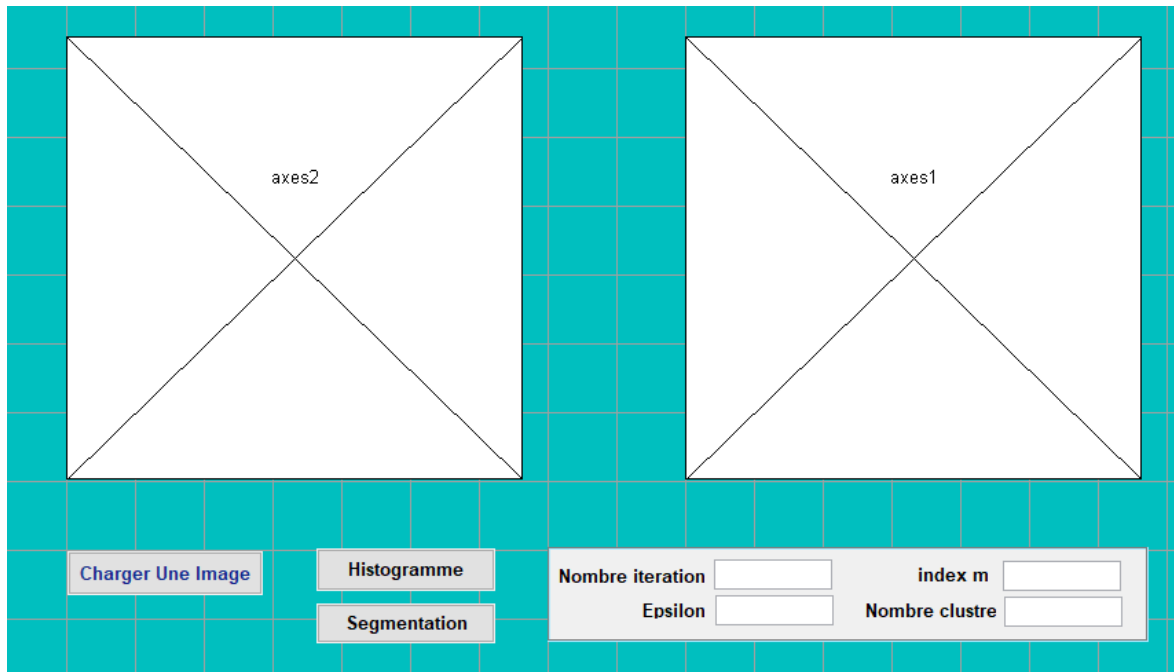


Figure IV.4 : Interface principale de l'application

6.2. Différentes fonctionnalités de l'application

6.2.1. Chargement de l'image

Il est possible de charger une image grâce au bouton **charger une image**.

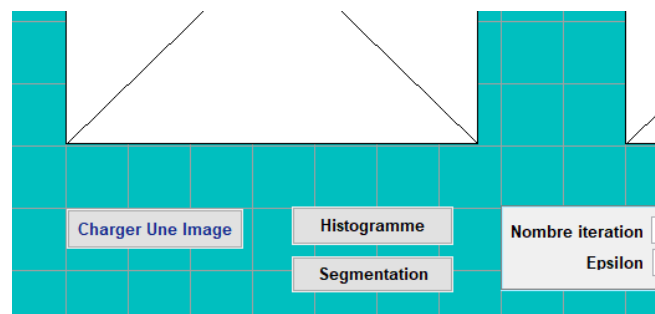


Figure IV.5 : Chargement d'une image.

6.2.2. Histogrammes de l'image :

Après avoir chargé une image, on peut également voir l'histogramme à partir duquel, on peut avoir une idée sur la valeur de k .

Il est possible d'afficher l'histogramme de l'image grâce au bouton **histogramme**.

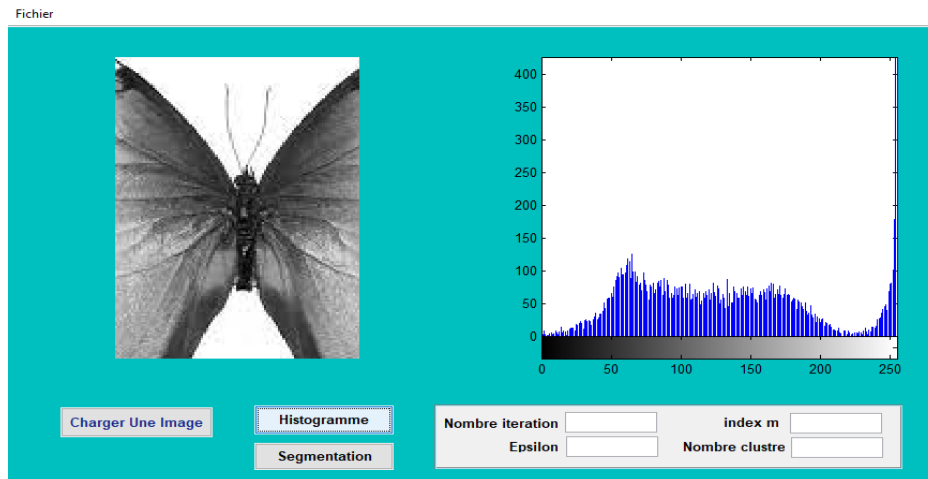


Figure IV.6 : histogramme de l'image (indique la valeur probable de k en nombre de pics)

6.2.3. Choix de paramètres :

Choix de paramètres (nombre de clustre, nombre d'itérations, la valeur fuzziness (index m), la valeur Epsilon).

Nombre iteration	<input type="text" value="100"/>	index m	<input type="text" value="2"/>
Epsilon	<input type="text" value="0.0001"/>	Nombre clustre	<input type="text" value="4"/>

Figure IV.7 : Chargement des paramètres

Les valeurs des paramètres de la segmentation sont des valeurs expérimental, elles ne doivent pas donner toujours de bons résultats pour toutes sortes d'images. Pour chaque image on peut fixer des valeurs différentes suivant des expérimentations déjà effectuées.

6.2.4. Lancement de l’algorithme FCM :

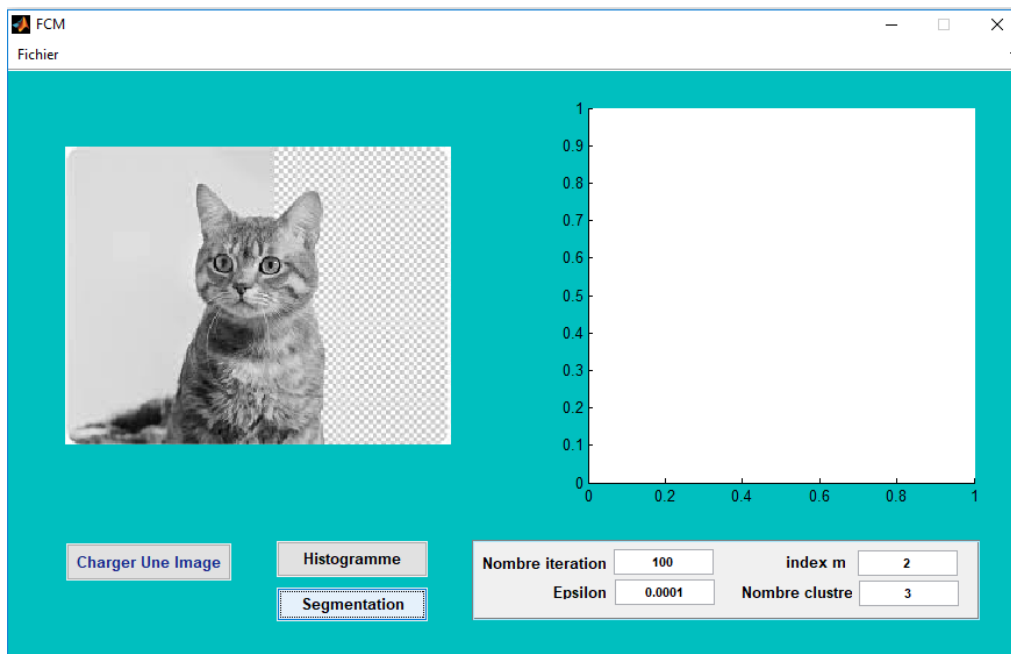


Figure IV.8 : lancement de FCM

7. Résultat de FCM :

Notre travail est la segmentation des images par la méthode de classification non supervisée Fuzzy C-Means qui est précédée par le choix du nombre de classes et le nombre maximum d’itérations ainsi que le paramètres floue et la valeur epsilon.

Les figures ci-dessous montrent les résultats de segmentation.

Test1 :

Paramètres de test : Nombre d’itérations **100** ,Nombre de classe **K=3**, Facteur de fuzzification **m=2**, Précision **Epsilon = 0.0001**

Temps de segmentation : 139 seconde

Résultat : $J = 1.5053e+07$, Nombre d’itérations = 66 , centroides (72.7436 , 154.2899 , 223.5240)

```

0.0006  0.0009  0.0009  0.0004
0.0065  0.0094  0.0094  0.0052
0.9930  0.9897  0.9897  0.9944

72.7436  154.2899  223.5240

1.5053e+07

66
    
```



Figure IV.9 : Résultat de segmentation avec FCM (Test1)

Test2:

Paramètres de test : Nombre d'itérations **200** ,Nombre de classe **K=5**, Facteur de fuzzification **m=2**,

Précision **Epsilon = 0.0001**

Temps de segmentation :862 seconde

Résultat : J = 4.9093e+06, Nombre d'itérations = 146 ,

Centroides (248.8367 ,112.0398 , 215.7040 ,54.9462 , 165.2948)

```

1.0000    0.9994    0.9994    1.0000
0.0000    0.0000    0.0000    0.0000
0.0000    0.0006    0.0006    0.0000
0.0000    0.0000    0.0000    0.0000
0.0000    0.0000    0.0000    0.0000

248.8367  112.0398  215.7040  54.9462  165.2948

4.9093e+06

146
    
```




Figure IV.10 : Résultat de segmentation avec FCM (Test2)

Test 3 :

Paramètres de test : Nombre d'itérations **300** ,Nombre de classe **K=7**, Facteur de fuzzification **m=2**,

Précision **Epsilon = 0.0001**

Temps de segmentation : 1571 seconde

Résultat : J = 2.8167+06 , Nombre d'itérations = 147

Centroides (51.4229 , 103.5908 , 232.3026, 217.9037, 194.5101, 152.1729 , 251.8011)

```

0.0000    0.0000    0.0000    0.0000
0.0000    0.0000    0.0000    0.0000
0.0000    0.0004    0.0004    0.0008
0.0000    0.0001    0.0001    0.0001
0.0000    0.0000    0.0000    0.0000
0.0000    0.0000    0.0000    0.0000
0.0000    0.0000    0.0000    0.0000
1.0000    0.9995    0.9995    0.9991

51.4229  103.5908  232.3026  217.9037  194.5101  152.1729  251.8011

2.8167e+06

147
    
```




Figure IV.11 : Résultat de segmentation avec FCM (Test3)

Après la série des tests avec le changement de nombre de class, la nombre d'itération , la facteur de Fuzzification et la précision en remarque que la qualité de segmentation augmentemais avec un cout de temps d'exécution un peu long, le facteur de Fuzzification doit être déterminé après une étude, aussi le nombre de classe aussi doit être connue à l'avance depuis l'histogramme mais la fixation d'un sue doit être fixé par un experte de télédétection.

Conclusion

Les résultats obtenues ont montrés que la méthode Fuzzy C-Means est performante d'un point de vu temps de calcul que celui de la qualité de l'image segmentée, cependant cette méthode peut être toujours sujet à des perfections en introduisant d'autres critères tel que le degré d'homogénéité de la classe et en testant d'autres types de distances.

Conclusion générale

Notre mémoire touche à sa fin et on a appris que la segmentation est l'étape la plus intéressante au traitement d'image.

De nos jours il existe plusieurs méthodes de segmentation et chacune d'elles est destinée à un domaine spécifique, nous avons présenté dans ce mémoire l'une de ces méthodes qui est la méthode Fuzzy C-Means. L'objectif de notre travail était de développer et détailler cette méthode qui est très utilisée dans plusieurs domaines, notamment, les Images en general.

Tous au long de ce mémoire on a su que la méthode Fuzzy C-Means (FCM) est un algorithme de classification non-supervisée floue. Elle introduit la notion d'ensemble flou dans la définition des classes : chaque point dans l'ensemble des données appartient à chaque cluster avec un certain degré d'appartenance, et tous les clusters sont caractérisés par leur centre de gravité (prototypes).

Cette méthode donne plutôt des résultats assez satisfaisants et ne prend pas beaucoup de temps au moins par rapport à d'autres méthodes non supervisées.

La méthode de FCM quoique théoriquement est considérée comme une méthode non supervisée, son implémentation n'est toutefois possible en tant que telle. Un guidage humain est nécessaire pour accélérer la convergence de l'algorithme et améliorer la qualité de la segmentation, ceci doit être traduit par une bonne initialisation des échantillons ainsi que le bonchoix de la valeur de k (nombre de classes) qui peut être déduite du nombre de pics importants dans l'histogramme de l'image à traiter. De ce fait, le processus de classification devient ainsi semi-automatique.

L'approche que nous avons adoptée n'est pas forcément la meilleure méthode pour obtenir la meilleure segmentation, elle n'est pas appropriée à tout type d'images. Nous avons constaté que l'algorithme nécessite une connaissance préalable du nombre de clusters à déterminer, ce qui rend impossible une éventuelle automatisation du processus. Par leur caractère itératif, ils s'avèrent inefficaces lorsque le nombre de clusters devient important.

Nous avons constaté que l'algorithme FCM est plus efficace que l'algorithme de k-means, du point de vue qualité de segmentation. Un simple coup d'œil sur les résultats obtenus montre clairement que les classes obtenues sont disjointes et plus ou moins homogènes en même temps, ceci est dû au fait de l'introduction de la logique floue dont l'apport a été bien traduit par la qualité de la segmentation obtenue.

Bibliographie

- [1] M .T.Chikh , amélioration des images par un modèle de réseau de neurones (comparaison avec les filtres de base), université abou-bakr belkaid tlemcen.2011
- [2] C.Houassine, segmentation d'images par une approche biomimétique hybride.université universite m'hamed bougara- boumerdes. 2012.
- [3] A.Medjaoui , f.fares , segmentation des images par contours actifs : application sur les Images Satellitaires à Haute Résolutions, Université Abou Bakr Belkaid–tlemcen.2012
- [4] T.Mohamed ,D.Djafar, la découverte des concepts sémantiques cachés avec plusieurs niveaux d'abstraction pour la recherche d'images,université kasdi merbah ouargla.2013
- [5] M Sandeli, traitement d'images par des approches bio-inspirées application à la segmentation d'images, université constantine 2. 2014.
- [6] N MERABET,M MAHLIA, recherche d'images par le contenu, université aboubakrbelkaid–tlemcen.2011
- [7] A. Krähenbühl. 2014''Segmentation et analyse géométrique : application aux images tomodensitométriques de bois''. Thèse de doctorat , École doctorale IAEM Lorraine.
- [8] L.Lechlek, M .Ghougal.2012''la segmentation d'image médicale par la méthode d'ensemble de niveaux (level sets)'' .Thésede Master, Université Larbi Ben M'hidi Oum El Bouaghi.
- [9] K. Aounallah, les approches de segmentation d'image par coopération régions-contours, 2010.
- [10] Bloch, Y. Gousseau, H. Maitre, D. Matignon, B. Pesquet-Popescu, F. Schmitt, M. Sigelle And F. Tupin, *Le traitement des images*, Polycopie du cours ANIM Département TSI - Télécom-Paris, 2005.
- [11] H.RAMI.2016'' Contribution au développement de descripteurs LBP pour le suivi d'objet en mouvement '' . Thèse de doctorat, Faculté des Sciences, 4 Avenue Ibn Battouta B.P. 1014 RP, Rabat – Maroc.
- [12] S.Belarouci,S.Benmokhtar , méthode coopérative pour la segmentation d'images IRM cérébrales basée sur les techniques FCM et level Set,. 2012
- [13] M. Melliani, segmentation d'image par cooperation regions-contours, magistère en informatique, ecole national supérieur d'informatique, 2012.
- [14] J. Canny, A, computational approach to edge detection, IEEE trans. on pattern analysis and machine intelligence, vol. 8, n°6, pp. 679-698, novembre 1986.

- [15] M. Sandeli. 2014 '' Traitement d'images par des approches bio-inspirées''. Thèse de magister, Université Constantine 2.
- [16] R. Deriche, Using Canny's criteria to derive a recursively implemented optimal edge detector, international journal of computer vision, pp. 167-187, 1987.
- [17] M.Meliani 2012''Segmentation d'Image par Coopération Régions-Contours''. Thèse de magister, Ecole nationale Supérieure en Informatique, Oued-Smar Alger, Ecole Doctorale STIC.
- [18] Michel Crucianu, Reconnaissance des formes et méthodes neuronales, Chapitre 5 : Classification automatique, CNAM Paris - RCP208 ,27/11/2009
- [19] François CHEVRIE, François GUÉLY, Cahier technique n° 191 « La logique floue », Collection Technique, CT 191 édition mars 1998.
- [20] MESLEM, mémoire de magister « Développement d'une approche d'intégration de la logique floue dans la représentation des connaissances », Institut National de formation en Informatique (I.N.I) Oued-Smar, Alger, 08-mars-2009.
- [21] Melle AKROUR Nawel, Melle CHABI Lilia, Mémoire de fin d'études , « Une plateforme évolutive pour le développement d'approches biomimétiques en segmentation d'images », Ecole nationale Supérieure d'Informatique (ESI) Oued-Smar, Alger, Promotion : 2008/2009
- [22] Jérémy Lecoeur, Christian Barillot, INSTITUT NATIONAL DE RECHERCHE EN INFORMATIQUE ET EN AUTOMATIQUE, Segmentation d'images cérébrales : État de l'art, Rapport de recherche, Thème BIO, inria-00175188, version 1 - 27 Sep 2007.
- [23] J. Dunn : A fuzzy relative of the ISODATA process and its use in detecting compact well-separated clusters. Journal of Cybernetics, 3:32–57, 1973.
- [24] R Nikhil, Pal and Kuhu Pal, J Bezdek "AMixed C-Means Clustering Model", 07803-3796-4/1987IEEE.
- [25] J Bezdek, "Pattern Recognition with Fuzzy Objective Function Algorithms" Plenum Press, New York, 1981.
- [26] J. Bezdek, J. Keller, N. Pal et R. Krisnapuram : Fuzzy Models And Algorithms For Pattern Recognition And Image Processing. Kluwer Academic Publishers, 1995.
- [27] P. Lambert, H. Greco, "A quick and coarse color image segmentation ", ICIP 2003, 14-17 Septembre, 2003.
- [28] Semchedine Moussa(1), Toumi Lyazid(2), Moussaoui Abdelouaheb (3), «Système Coopératif de Classification Floue Possibiliste avec Rejet d'Ambiguïté 'Application à la segmentation d'images IRM ' », (1) Département d'Informatique - Université Ferhat Abbas de Sétif, (2,3) Ecole doctorale nationale STIC Département d'Informatique -Université Ferhat Abbas

de Sétif, 4th International Conference on Computer Integrated Manufacturing CIP'2007 ,03-04 November 2007

- [29] V Barra V, "Fusion d'Images 3D du Cerveau : Étude de Modèles et Applications", Ph.D. Thesis, Université d'Auvergne, Clermont-Ferrand (France), 2000.
- [30] V Barra, JY Boire, "Fusion de Données en Imagerie 3D du Cerveau, l'incertitude et l'imprécision en fusion d'informations : théories et applications", Clermont-Ferrand, 16 Juin 1999.
- [31] Gilson BRAVIANO, Thèse de doctorat, « Logique floue en segmentation d'images : seuillage par entropie et structures pyramidales irrégulières », Université Joseph Fourier – Grenoble 1, Date de soutenance : 03 octobre 1995.
- [32] Jelena Godjevac. « Idées nettes sur la logique floue ». Presses polytechniques et universitaires Romandes, Lausanne, 1999.
- [33] E. H. Ruspini. A new approach to clustering. Inform. Control, 15(1):22–32, 1969.
- [34] Lloyd, S. P. (1957). "Least square quantization in PCM". Bell Telephone Laboratories Paper. Published in journal much later: Lloyd, S. P. (1982). "Least squares quantization in PCM". IEEE Transactions on Information Theory 28 (2): 129–137. doi:10.1109/TIT.1982.1056489. Retrieved 2009-04-15